

PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ

FACULTAD DE CIENCIAS E INGENIERÍA



PONTIFICIA
UNIVERSIDAD
CATÓLICA
DEL PERÚ

**SISTEMA DE DETECCIÓN DE FALLAS PARA UN MOTOR DC
MEDIANTE FILTROS DE KALMAN**

Tesis para optar el Título de Ingeniero Electrónico, que presenta el bachiller:

Jan-André Dubois Farfán

ASESOR: PhD Juan Javier Sotomayor

Lima, Junio del 2011

Resumen

Las metodologías para la determinación e identificación de fallas en procesos industriales viene siendo desarrollada e investigada desde hace 30 años, en los cuales se han elaborado una gran variedad de metodologías de detección y de aplicaciones a sistemas reales.

Debido al aumento de la complejidad y cantidad de los procesos que necesitan ser controlados, surgen teorías para la detección e identificación de fallas como solución a problemas de repercusión no solo económica, sino también ecológica, productiva y de seguridad.

En la presente tesis se ha desarrollado un método de detección e identificación basado en una innovación proveniente del filtro de Kalman, la cual provee condiciones suficientes y necesarias para la detección de fallas aditivas bajo influencia de ruido gaussiano blanco. Esta metodología de detección se aplica a un motor de corriente continua de excitación independiente, cuya función de transferencia tipo SISO ha sido obtenida experimentalmente.

Posteriormente un análisis estadístico de la innovación obtenida del filtro de Kalman, ha permitido diagnosticar la presencia e instante de la falla aditiva generada en el sensor del sistema. Lo anterior ha generado un sistema capaz de detectar fallas aditivas idealizadas como modelos tipo escalones y rampas en un sistema lineal e invariante en el tiempo.

El sistema desarrollado, permite la correcta detección e identificación de las fallas aditivas presentes en el sensor del modelo del motor de corriente continua, basándose en el análisis estadístico del parámetro innovación proveniente del Filtro de Kalman.

Contenido

Introducción	3
1. Problemática de la Deteccion y Aislamiento de Fallas	5
1.1. Introducción	5
1.2. Importancia del Motor de Corriente continua y la Detección de Fallas	6
1.3. Estado del Arte: Detección y Determinación de Fallas	6
1.3.1. Introducción	6
1.3.2. Fallas	6
1.3.3. Características deseables en un sistema de diagnóstico de fallas	7
1.3.4. Clasificación de los Métodos de Detección de Fallas	8
1.3.5. Método a emplear	19
1.4. Objetivos de la Tesis	19
1.4.1. Objetivo General	19
1.4.2. Objetivos Específicos	19
2. Detección de Fallas en Motores de Corriente continua	20
2.1. Características de los Motores de Corriente Continua	20
2.2. Motor de Corriente Continua de excitación independiente	21
2.2.1. Modelo Matemático del Motor de Corriente continua de excitación independiente	21
2.3. Identificación del Sistema	22
2.3.1. Método de Ziegler-Nichols en lazo abierto	23
2.3.2. Identificación mediante la Herramienta de Identificación de Sistemas	27
2.4. Escenario de Fallas	33

3. Diseño de un sistema de Detección y Aislamiento de fallas	35
3.1. Filtro de Kalman	35
3.1.1. El Filtro de Kalman Discreto	36
3.1.2. Modelo gráfico del Filtro de Kalman	40
3.2. Cambios Aditivos en Modelos Lineales	40
3.2.1. Cambios Aditivos en Modelos de estado espacio	41
3.2.2. Innovación y Redundancia	43
3.3. Diseño del Sistema de Detección de Fallas	44
3.3.1. Generación de Residuos	46
3.3.2. Evaluación del Residuo	48
3.3.3. Simulación de Filtro de Kalman para la detección de Fallas	52
4. Pruebas y Análisis de Resultados	59
4.1. Introducción	59
4.2. Resultados y Análisis de la Innovación	59
4.2.1. Modelamiento sin Falla	59
4.2.2. Modelamiento con Falla	61
4.2.3. Análisis de los Resultados	65
4.3. Resultados y Análisis del GLR	66
4.3.1. Modelamiento sin Falla	66
4.3.2. Modelamiento con Falla	67
4.3.3. Análisis de los Resultados	70
Conclusiones	72
Recomendaciones	73
Bibliografía	74

Índice de figuras

1.1. Diagrama básico de tipología de fallas[1]	7
1.2. Esquema de Métodos de Diagnóstico de Detección de Fallas[2]	9
1.3. Esquema general del uso de redundancia analítica[1]	10
1.4. Tipología de observadores en procesos dinámicos [1]	11
1.5. Detección de fallas con ecuaciones de paridad en Procesos Dinámicos [1]	12
1.6. Dinámica de ciclos de predicción consecutiva y filtrado en Filtros de Kalman [3]	13
1.7. Concepto Dinámico de los EKF [3]	14
1.8. Formas de conocimiento cualitativo basados en el modelo del proceso[4]	14
2.1. Conexiones del Motor DC	23
2.2. Herramienta de Simulación del Motor DC	24
2.3. Curva estática del Motor DC	25
2.4. Respuesta Transitoria ante entrada tipo escalón	25
2.5. Retardo de la respuesta transitoria ante una entrada escalón	26
2.6. Punto t_{63}	26
2.7. Modelamiento de la Respuesta Transitoria Modelo del Proceso a una función de primer orden	28
2.8. Aproximación del sistema una función de Primer orden con retardo . . .	28
2.9. Respuesta transitoria del sistema ante una entra tipo escalón	29
2.10. Modelamiento de la respuesta transitoria del proceso a una función de segundo orden	30
2.11. Aproximación del sistema a una función de Segundo orden con retardo .	30
2.12. Modelamiento de la respuesta transitoria del proceso a una función de segundo orden con un cero	31
2.13. Aproximación del sistema a una función de segundo orden con retardo y un cero	32

2.14. Respuesta transitoria ante entrada escalón real y la estimada	32
3.1. Dinámica de ciclos de predicción consecutiva y filtrado en Filtros de Kalman [3]	35
3.2. Modelamiento del Filtro de Kalman[5]	40
3.3. Cambios aditivos en un modelo de estado espacio[5]	42
3.4. Esquema general de detección y diagnóstico de fallas	45
3.5. Representación gráfica del modelamiento del filtro de Kalman	48
3.6. Herramienta de Simulación General para la detección de fallas	53
3.7. Modelo del Sistema sin Fallas	55
3.8. Modelo del sistema con fallas tipo escalón	56
3.9. Modelo del sistema con fallas tipo rampa	56
3.10. Subsistema para el cálculo estadístico del proceso	57
4.1. Innovación proveniente del Filtro Kalman sin presencia de falla	60
4.2. Media de la Innovación proveniente del Filtro Kalman sin presencia de falla	60
4.3. Desviación de la Innovación proveniente del Filtro Kalman sin presencia de falla	61
4.4. Comparación en la salida para modelos sin falla y con falla escalón	61
4.5. Innovación proveniente del Filtro Kalman en presencia de falla escalón	62
4.6. Media de la Innovación proveniente del Filtro Kalman en presencia de falla escalón	62
4.7. Desviación de la Innovación proveniente del Filtro Kalman en presencia de falla escalón	63
4.8. Comparación en la salida para modelos sin falla y con falla rampa	63
4.9. Innovación proveniente del Filtro Kalman en presencia de falla rampa	64
4.10. Media de la Innovación proveniente del Filtro Kalman en presencia de falla rampa	64
4.11. Desviación de la Innovación proveniente del Filtro Kalman en presencia de falla rampa	65
4.12. Ratio generalizado de verosimilitud en modelo sin fallas	66
4.13. Estimación del tiempo de falla en modelo sin fallas	67
4.14. Ratio generalizado de verosimilitud en modelo con falla escalón	67
4.15. Estimación del tiempo de falla en modelo con falla escalón	68
4.16. Ratio generalizado de verosimilitud en modelo con falla rampa	69
4.17. Estimación del tiempo de falla en modelo con falla rampa	69

Introducción

La detección de fallas, como uno de los requerimientos principales en cualquier planta industrial ha tenido una gran evolución en los últimos años, debido principalmente a la aparición de sistemas cada vez más complejos, entre los cuales encontramos sistemas de captación de señales (sensores), de procesamiento de información, etc. Esta evolución de requerimientos en la industria, sigue generando nuevos sistemas de detección de fallas, debido a ello, en la presente tesis se desarrollará el diseño de un sistema de detección e identificación de fallas de sensores basado en filtros de Kalman para un motor de corriente continua mediante simulaciones en Matlab.

En el capítulo 1, se desarrollarán conceptos importantes para entender el procedimiento en la detección de fallas, definiendo el concepto de falla, su origen y sus tipos, posteriormente se realizará una descripción general de los principales métodos de diagnóstico de fallas, basados tanto en el modelo del proceso y en el proceso histórico.

En cuanto a los métodos basados en el Modelo del proceso, encontramos a los modelos basados en métodos cuantitativos, los cuales se basan en los fundamentos físicos del proceso, que son expresados entre las entradas y salidas del sistema y cuya mayor ventaja es el control sobre el comportamiento de los residuos generados. Además, encontramos al Filtro de Kalman, el cual es un estimador de estado con el mínimo error de estimación, este se expresa mediante un algoritmo recursivo para la estimación del estado.

En cuanto a los Modelos basados en métodos cualitativos, los cuales pueden ser desarrollados a través de modelos cualitativos causales, árboles de fallas o física cualitativa. Los modelos causales se desarrollan mediante el uso de diagramas que son capaces de describir el comportamiento del sistema siendo representadas mediante gráficos dirigidos que buscan la deducción de modelo o estructura adecuada a un comportamiento específico relacionando la causa y el efecto, sin embargo cabe notar que la detección de fallas de este modelo es limitada ya que considera que una falla primaria es un cambio de variable. En el Árbol de Fallas, se busca la propagación de defectos al acontecimiento de nivel superior, buscando el origen elemental de la falla. Para el análisis de fallas cuenta con 4 etapas: definición del sistema, construcción del árbol de fallas, evaluación cualitativa y evaluación cuantitativa. Sin embargo, su desarrollo es propenso a errores en diferentes etapas debido que depende de quién creó el modelo mental, por ello no hay forma de verificar la exactitud del árbol de fallas desarrollado.

Respecto a la Física Cualitativa, actúa mediante metodologías para así poder relacionar los modelos cualitativos a partir del comportamiento matemático o funcional de la planta logrando proporcionar explicaciones del comportamiento basado en observaciones de proceso y descripción de sistema. Su ventaja es la creación de conclusiones parciales del conocimiento incompleto y a menudo del conocimiento incierto del proceso.

En el Capítulo 2, se realizará una descripción del motor de Corriente continua, como una máquina eléctrica que transforma la energía eléctrica en energía mecánica y se basa en el principio de repulsión magnética por las corrientes que circulan por las espiras, describiendo más detalladamente al motor de corriente de excitación independiente, su modelo, sus ecuaciones y características que lo definen.

Posteriormente, para el modelamiento del sistema se ha desarrollado un modelo de un sistema donde se encuentran el actuador, el motor de corriente continua y el sensor, usando el método de Ziegler-Nichols en lazo abierto se determinó el rango lineal del modelo según la curva estática generada y posteriormente, según el rango lineal obtenido se generó la curva dinámica del sistema para la posterior obtención de una función de transferencia que define al sistema de entrada-salida. La función de transferencia obtenida anteriormente, es comparada con diferentes ordenes de sistemas extraídos de los datos reales y analizados mediante la herramienta de Identificación de sistemas, obteniéndose un mayor índice de adecuación (98,12 %) para un sistema de segundo orden con cero.

En el capítulo 3, se define el filtro de Kalman, su importancia como estimador óptimo de procesos lineales que son afectados por ruidos blancos gaussianos tanto en el proceso como en la lectura. Así mismo, se define las ecuaciones recursivas que caracterizan a este método de estimación.

Se plantea los fundamentos y características de la detección de fallas aditivas para sistemas lineales, dando énfasis a la representación estado espacio. Posteriormente se define los criterios de diseño para la correcta identificación de la falla mediante el análisis estadístico de la innovación proveniente del filtro de Kalman.

En el capítulo 4, se muestran los resultados y el análisis respectivo del sistema de detección de fallas aditivas generadas de los residuos provenientes del parámetro innovación del Filtro de Kalman, corroborando los criterios establecidos de diseño para la correcta detección de la falla.

Finalmente, se enfatizan las conclusiones obtenidas del diseño del sistema de detección de fallas y su aplicación al motor de corriente continua de excitación independiente.

Capítulo 1

Problemática de la Deteccion y Aislamiento de Fallas

1.1. Introduucción

Desde hace más de 30 años, la detección de fallas es un requerimiento indispensable en toda planta, en la actualidad sigue teniendo un incremento progresivo, debido principalmente a las necesidades tecnológicas de nuevos y complejos procesos, así la detección de fallas se presenta como respuesta a las nuevas necesidades producto de los mismos cambios tecnológicos.

Las necesidades, tales como son la oportuna detección de fallas y su diagnóstico, la búsqueda de seguridad de sistemas cada vez más complejos, la mejora de calidad de control, así como la disponibilidad de novedosos sistemas de captación de señales (sensores), y el uso de sofisticados sistemas de procesamiento de información, los cuales han planteado la creación e implementación de complejos algoritmos de monitoreo; originando la búsqueda de soluciones a problemas cada vez más numerosos y frecuentes concernientes a la detección e identificación de fallas, así como su diagnóstico y tratamiento.

En la actualidad, las plantas industriales, como sistemas integrales donde intervienen diferentes tipos de variables a medir y complejos procesos, tienen nuevos requerimientos relacionados con la efectividad tanto económica, así como efectividad del proceso mismo. Debido al aumento de la complejidad y cantidad de los procesos que necesitan ser controlados, surgen teorías para la detección e identificación de fallas como solución no solo económica, sino también ecológica, productiva y de seguridad.

Hoy en día, procesos como apertura y cerrado de válvulas, llenado de tanques o encendido de máquinas que eran realizados antes por operarios, ahora son realizados de forma rutinaria por sistemas autónomos controlados por computadores u otros sistemas de control, dándonos así la imagen del avance de los sistemas de control en muchas ramas de la industria como son la química, la petroquímica, la de cemento, la siderúrgica, entre muchas otras. [1]

1.2. Importancia del Motor de Corriente continua y la Detección de Fallas

El motor DC es uno de los elementos más importantes y versátiles en la industria, debido a sus características particulares como son: inercia pequeña o una alta relación de par e inercia, de igual manera su fácil control de posición, par y velocidad, estas particularidades lo han convertido en una de las mejores opciones de aplicaciones de control y automatización de procesos, sistemas robóticos, así como el fresado y mecanizado de piezas.

Por ello, un sistema que pueda detectar las fallas e identificarlas en un motor DC, beneficiará no sólo al proceso de detección de fallas, sino también colaborará con un mantenimiento predictivo del motor y de los elementos que interactúan con el motor DC.

Así mismo, con un control realimentado adecuado se generarán soluciones oportunas a cada tipo de falla detectada, evitando pérdidas económicas por el detenimiento parcial o total de la planta, costos por las reparaciones o cambios forzados de elementos de desgaste continuo. Generándose un mantenimiento constante y permanente, aumentando la vida útil del motor DC, y por consiguiente el buen desempeño de la planta.

1.3. Estado del Arte: Detección y Determinación de Fallas

1.3.1. Introducción

Debido a que el principal objetivo de la detección y determinación de fallas (FDI), es la detección de la existencia de la falla y su posterior determinación, es necesario un conocimiento del significado de falla, para luego realizar una revisión de las características principales que deben tener los sistemas para detección de fallas y por último una descripción de las principales teorías de detección de fallas.[1]

1.3.2. Fallas

Una falla se define como aquel proceso o síntoma fuera de lo normal, es decir que no estaba contemplado dentro de un rango aceptable, pudiendo ser ese rango de una variable calculada o una observada dentro de un proceso.

1.3.2.1. Tipología de Fallas

Las fallas son originadas por una diversidad de factores que dependen del mismo sistema como de otros factores externos, sin embargo las fallas más comunes presentes en la mayoría de sistemas son las que se muestran en la figura 1.1.

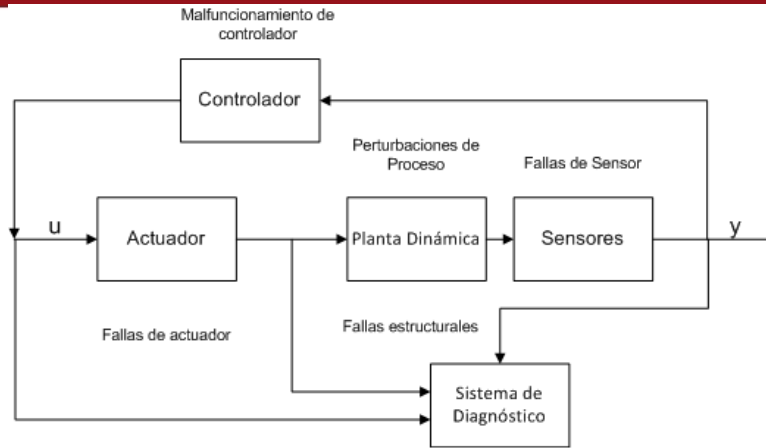


Figura 1.1: Diagrama básico de tipología de fallas[1]

En donde, según el origen de las fallas se tiene:

- Fallas en los sensores y actuadores

Los sensores son instrumentos de extracción de variables medidas en las plantas, estos instrumentos también son inherentes a sufrir fallas, entre las cuáles están las fallas por reparación, fallas de fuera de rango, así mismo las fallas ocasionadas por el ruido aditivo; es por ello que es necesario hacer una rápida corrección debido a que una lectura errónea de algún instrumento o una falla en el actuador pueden generar cambios drásticos e importantes, originando serias degradaciones en el desempeño de los sistemas de control.

- Fallas por cambios estructurales

Se tratan de cambios en el mismo proceso que ocurren debido principalmente a fallas o desgaste en los equipos, los cuales generan cambios en el flujo de información entre las diferentes variables. Algunos ejemplos son: las fallas en el controlador, así como válvulas atoradas o conductos rotos.

- Fallas en cambios de parámetros externos

Ocurren cuando hay partes del proceso que no son modeladas, estas partes tienen niveles establecidos para el buen funcionamiento, pero si estos niveles pueden cambiar debido a perturbaciones que entran en el proceso provenientes del ambiente a través de las variables del sistema.[1]

1.3.3. Características deseables en un sistema de diagnóstico de fallas

- Rápida detección y diagnóstico

La búsqueda de rapidez en la detección y diagnóstico, es una de las principales características que se busca de un sistema, pero en esa búsqueda de rapidez el sistema se vuelve sensible a influencias de grandes frecuencias, haciéndolo sensible al ruido pudiendo provocar falsas alarmas durante un normal funcionamiento.

- Aislamiento

Es la habilidad de los sistemas de diagnóstico de diferenciar entre diferentes fallas, pero existe una relación inversa con la repulsión ante las incertidumbres de modelos. Es decir, a más grande el nivel de aislamiento, poseerá menor posibilidad de rechazar las incertidumbres de los modelos y viceversa.

- Robustez

Se busca que el sistema sea robusto ante diferentes ruidos e incertidumbres, a la vez que en su funcionamiento el degradamiento no sea brusco, evitando así fallar totalmente. Los umbrales de robustez en presencia de ruido deben estar cercanos al valor de 0 y deben tener concordancia con el funcionamiento general del sistema.

- Adaptabilidad

Los procesos en general, son dependientes no sólo de las entradas externas o de los cambios estructurales, sino también dependen de las perturbaciones y de los cambios medioambientales, es por ellos que el sistema de diagnóstico debe ser adaptable a todos esos cambios y tener la posibilidad de ser reestructurado para nuevos casos o problemas que surjan.

- Requerimientos de modelos

Para una rápida detección y clasificación en tiempo real el modelo debe ser lo más simple posible.[1]

1.3.4. Clasificación de los Métodos de Detección de Fallas

En la figura 1.2 se muestra un esquema de clasificación de las métodos de diagnóstico de fallas.

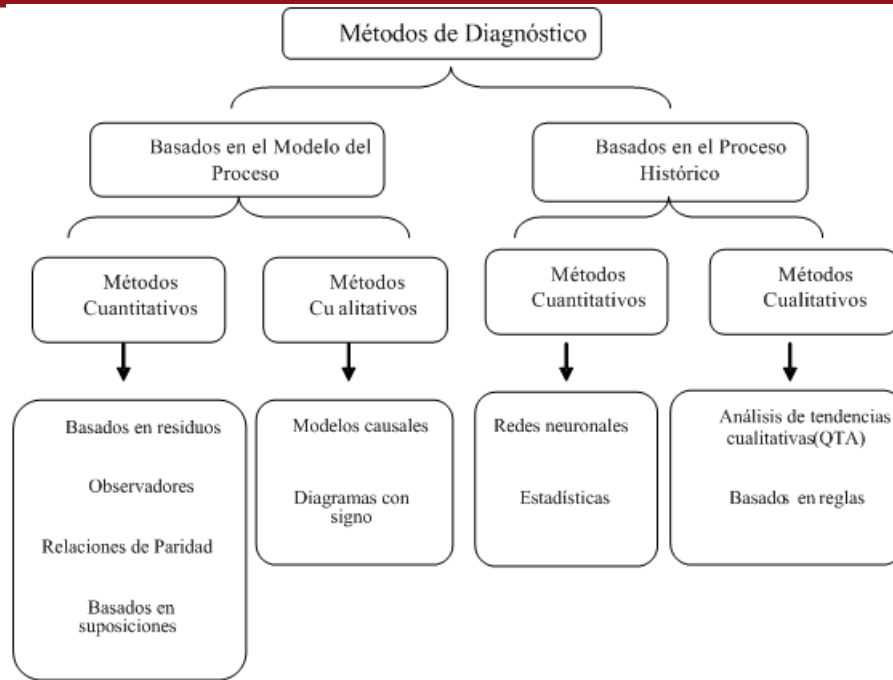


Figura 1.2: Esquema de Métodos de Diagnóstico de Detección de Fallas[2]

Se describirán los métodos basados en el modelo del proceso, los cuales están relacionados con el tema de la presente tesis.

Métodos cuantitativos basados en modelos de proceso

El modelo es usualmente desarrollado, basado en el entendimiento de los fundamentos físicos del proceso, este entendimiento es expresado en términos de relaciones matemáticas funcionales entre las entradas y las salidas del sistema. La mayor ventaja del uso de modelos basados en métodos cuantitativos es el control sobre el comportamiento de los residuos generados, sin embargo, varios factores como la complejidad de los sistemas o grandes dimensiones, así como su no linealidad hacen que este método sea difícil para el desarrollo de un modelo matemático exacto.

Para estos modelos se desarrollará un primero paso, que es crear diferencias entre el comportamiento actual y el esperado, estas señales artificiales también llamadas residuos, reflejan las potenciales fallas en el sistema. Para el segundo paso, se basa en las características de este residuo, desarrollando reglas de decisiones para su diagnóstico.

Para la detección de las diferencias es necesaria cierta forma de redundancia, pudiendo ser por hardware o analítica. La redundancia por hardware no es usada frecuentemente por los costos de sensores extras y el espacio limitado, mientras que la redundancia analítica o artificial es desarrollada por la dependencia funcional sobre las variables del proceso, dicha dependencia usualmente es hecha a partir de las relaciones algebraicas o temporales de las entradas y salidas.

La redundancia analítica se clasifica en:

Directa, que es realizada mediante las relaciones algebraicas entre diferentes medidas de los sensores, siendo estos guardados y luego comparados con el valor leído del sensor. Temporal, que es obtenida de la relación diferencial entre salidas de los sensores y entradas de actuadores, por lo que es muy útil para detección de fallas en sensores y actuadores.[1]

En la figura 1.3 se muestra el esquema general de uso de redundancia analítica.

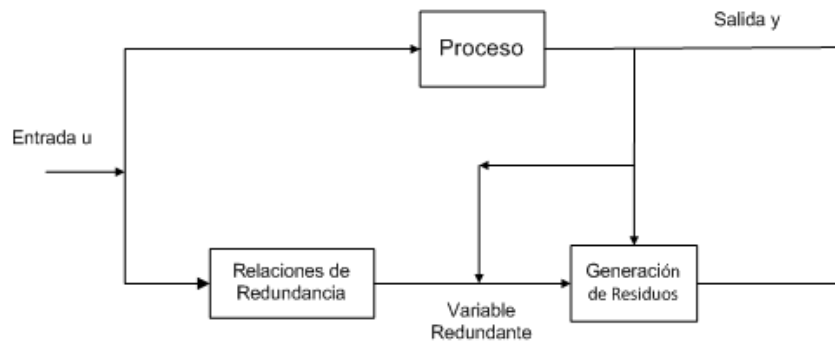


Figura 1.3: Esquema general del uso de redundancia analítica[1]

La esencia de la redundancia analítica en la detección de fallas es revisar el comportamiento actual del sistema frente al modelo del sistema buscando que sean consistentes, cualquier inconsistencia es expresada como un residuo, el cuál será usado para la detección y aislamiento. Cuando no ocurren fallas, ese residuo debería ser cercano a cero, pero debe mostrar un valor significativo cuando ocurre alguna falla. La utilización de este modelo es generalmente para sistemas lineales debido al conocimiento más exacto de las ecuaciones del modelo. Sin embargo, puede ser utilizado para sistemas no lineales, donde previamente se da linealidad alrededor del punto de operación.[1]

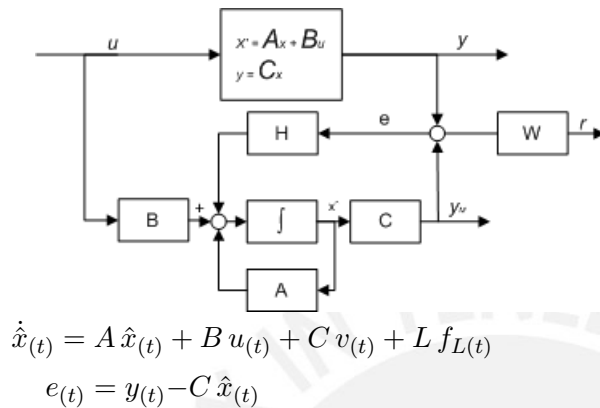
Observadores

En un proceso, donde los parámetros del proceso son conocidos, pueden ser usados los observadores de estado o los observadores de salida. En la figura 1.4 se muestran ambos tipos de observadores para procesos en los cuales existen fallas de tipo aditivas, donde f_L es una falla aditiva en el actuador o una falla de proceso y f_M es una falla de lectura en el sensor.

$$\begin{aligned}\dot{x}(t) &= Ax(t) + Bu(t) + Cv(t) + Lf_L(t) \\ y(t) &= Cx(t) + Nn(t) + Mf_M(t)\end{aligned}$$

$n(t) v(t)$ señales de perturbacion $f_L(t), f_M(t)$ fallas aditivas

Observadores de estado



Observadores de salida




Figura 1.4: Tipología de observadores en procesos dinámicos [1]

Observadores de estado

Los clásicos observadores de estado pueden ser aplicados si la falla puede ser modelada como un cambio del estado de la variable ($\Delta\theta$). En el caso de ser procesos con varias salidas se proponen diferentes arreglos, tales como:

- Observadores dedicados para procesos con varias salidas:

Observador excitado con una salida, las demás salidas son reconstruidas y comparadas con las salidas medidas, permitiendo la detección de solo un error del sensor.

Banco de observadores excitados por todas las salidas, varios observadores de estado son diseñados para un tipo de señal de falla y detectada bajo una prueba hipotética.

Banco de observadores excitados por una única salida, varios observadores para un único sensor de salida, las salidas estimadas son comparadas con las salidas medidas, permitiendo la detección múltiple de fallas del sensor.

Banco de observadores excitados por todas las salidas excepto una de ellas, igual que el banco anterior pero cada observador es excitado por todas las salidas excepto una salida del sensor la cual es supervisada.

- Filtros sensitivos a fallas para procesos con varias salidas:

El lazo de realimentación H del observador de estado es elegido para un valor particular de la falla $f_L(t)$ cambia en una dirección definitiva y la falla de la señal $f_M(t)$ cambia en un plano definitivo.[1]

Observadores de salida

Otra posibilidad, es el uso de observadores de entrada desconocida (*UIO*), si la reconstrucción de las variables de estado no es de interés, los residuos pueden ser designados como independientes de las entradas desconocidas, por lo que sólo dependen de las fallas aditivas $f_{L(t)}$ y $f_{M(t)}$. En el diseño de un observador, no es necesaria la aplicación de la teoría de estimación de estado (*state estimation*), en vez de ello es necesario el uso de filtros como estimadores de las salidas. [6]

La importancia de la búsqueda de robustez en los observadores, es debido a la dependencia respecto del modelo, cuanto más complejo sea un modelo entonces más difícil será la técnica, volviéndose indispensable la robustez del observador.[7] Algunos de los primeros investigadores, usando detección de fallas con observadores fueron: Clark [8], Massoumnia [9] ,entre otros, pero Frank [6] presentó la solución al problema fundamental de la robustez en la detección de fallas, dándole la robustez lograble separando los efectos de cada una de las fallas de los efectos por los errores de modelamiento del sistema. Además, la aparición de observadores para sistemas no lineales es analizada por Frank, [6] donde se le asigna un modelo continuo en el tiempo para las no lineales, y basándose en el procedimiento para los observadores lineales se logra un modelo adecuado.

También se crearon observadores específicos no lineales para un tipo especial de sistemas no lineales, entre los cuales tenemos observadores para sistemas con no linealidad bilineal [10] y observadores basados en métodos geométricos diferenciales [11, 1].

Relaciones de Paridad

Este método fue introducido por Willsky [7] , en donde las ecuaciones de paridad son reorganizaciones y usualmente variantes transformadas de plantas tipo entrada-salida o estado espacio. La esencia es el revisar la paridad o consistencia de la planta usando sensores a la salida y conociendo las entradas al proceso. En la figura 1.5, se muestra las ecuaciones de paridad y metodología utilizada, tanto para el modelo de entrada - salida , así como para el modelo estado espacio.




Figura 1.5: Detección de fallas con ecuaciones de paridad en Procesos Dinámicos [1]

La evolución de este método fue desarrollada dándole la inclusión de nuevos aspectos como el uso de promedios de términos cortos para el balance de las ecuaciones residuales [12], la generación de residuos ortogonales para diferentes tipos de fallas [13], la determinación de un aislamiento garantizado bajo condiciones ideales [14] así como bajo condiciones de bajo ruido[15], pero aun así todavía están limitados a fallas donde no ocurre una total caída de los parámetros del proceso, ni toman en cuenta las significativas incertidumbres de las fallas paramétricas multiplicativas [1].

Filtros de Kalman

Las perturbaciones en plantas son fluctuaciones aleatorias y solamente en algunas ocasiones podemos tener acceso a sus parámetros estadísticos, es debido a este inconveniente que un correcto diagnóstico de fallas implica monitorear las predicciones del error o el proceso de innovación.

El objetivo es el diseño de un estimador de estado con el mínimo error de estimación, los filtros de Kalman son un tipo de ellos, siendo diseñado sobre la base del modelo del sistema en su modo de operación normal.

El filtro de Kalman es un algoritmo recursivo para la estimación del estado, es debido a ello que en un modelo de espacio estado es equivalente a un predictor óptimo en un sistema lineal estocástico de entrada salida. En la figura 1.6 se muestra los ciclos del filtro de Kalman, el primero de predicción donde estima la salida del sistema y posteriormente el ciclo de filtrado donde minimiza el error de predicción a posteriori.




Figura 1.6: Dinámica de ciclos de predicción consecutiva y filtrado en Filtros de Kalman [3]

El Filtro de Kalman, genera una ganancia que es dependiente del tiempo, la cuál multiplicada con la estimación del error generará la estimación próxima de las variables de estado. Para poder diferenciar las fallas, se considera un banco de filtros de Kalman para todas las posibilidades de cambios[1].

Entre la variedad de filtros de Kalman, un filtro importante es el Filtro de Kalman Extendido (*EKF*), el cual es usado en sistemas no lineales designando detecciones mediante filtros locales, basándose en aproximaciones lineales en sistemas no lineales alrededor de su última estimación.

En la figura 1.7 se muestra la utilización de los ciclos de predicción y filtrado del filtro de Kalman para un proceso donde se toma un rango lineal alrededor del último punto de estimación.

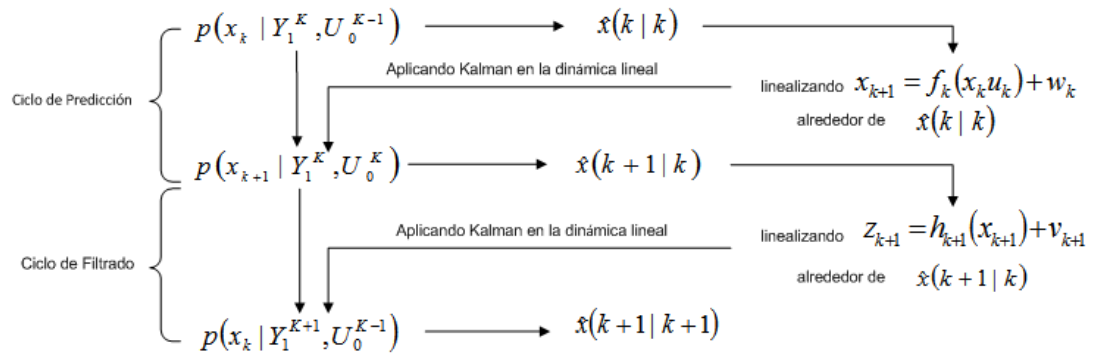


Figura 1.7: Concepto Dinámico de los EKF [3]

Además de los EKF, encontramos nuevos métodos de reducción del orden de los filtros basándose en un algoritmo que identifica las entradas desconocidas como funciones de una variable, mientras que los demás parámetros son independientes de dicha variable. [2]

Métodos cualitativos basados en modelos de proceso

Las relaciones de los modelos cualitativos son expresadas en términos de funciones cualitativas centradas alrededor de unidades diferentes en el proceso. Los modelos cualitativos pueden ser desarrollados a través de modelos cualitativos causales o jerarquías de abstracción. En la figura 1.8, se muestran las principales metodologías presentes en la clasificación de los modelos basados en métodos cualitativos, teniendo 2 principales clasificaciones en métodos causales y en jerarquías de abstracción.

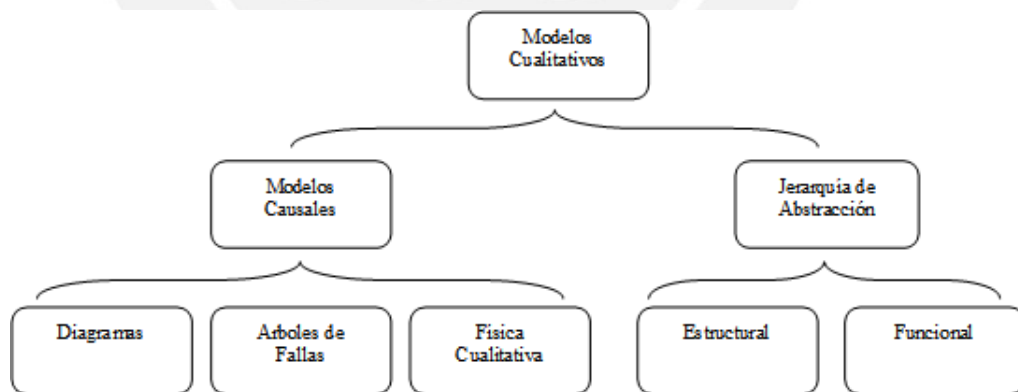


Figura 1.8: Formas de conocimiento cualitativo basados en el modelo del proceso[4]

El desarrollo de conocimiento basado en sistemas expertos, fue el primer intento de capturar conocimiento para plasmar conclusiones usando una metodología formal. Un sistema experto es un programa de computadora que imita el comportamiento cognitivo de un ser humano experto resolviendo problemas en un dominio particular.

Dicho sistema experto consiste en una base de conocimiento, esencialmente un conjunto de reglas “if – then - else”, que varían con la complejidad del sistema, y una máquina

de inferencias, la cual busca a través del conocimiento base para crear conclusiones de los hechos dados. El problema con este tipo de representación de conocimiento es que no posee ningún entendimiento de la base física del sistema, por lo que falla cuando nuevas condiciones son encontradas y no fueron definidas en la base al conocimiento. [4]

En el razonamiento simbólico, existen tres clases diferentes de razonamiento, que son abductivo, inductivo y predeterminado. El razonamiento abductivo es la generación de una explicación hipotética o la causa para lo que ha sido observado. A diferencia de la deducción simple lógica, podemos conseguir más que una respuesta en el razonamiento abducido. Debido a que no existe una forma general de decidir entre varias alternativas, lo más adecuado es encontrar la hipótesis más probable, por lo que sería un razonamiento donde sopesamos las evidencias en la presencia de incertidumbre. La búsqueda de la causa de una anomalía en un sistema de proceso es un razonamiento abductivo. El razonamiento abductivo provee además explicaciones de cómo la causa podría haber producido la anomalía observada, dicha facilidad es útil, debido a que proporciona sustento a las decisiones de los operadores de planta. El razonamiento inductivo está basado en la generalización o especialización de una definición de un concepto aprendido mediante la unión de todas las experiencias pertenecientes a dicho concepto, y excluyendo a las que no pertenecen. Por ello, no se puede obtener una definición clara de un concepto, debido a la gran variedad de experiencias e incertidumbre (datos ruidosos u observaciones). Por esta razón, se prefiere un esquema de aprendizaje adaptable, un ejemplo es el aprendizaje por fracasos, el cual refina el concepto del fracaso como expectativas de como uno ha relacionado sus experiencias.

La importancia del razonamiento predeterminado está basada en su característica de ser no monotónico, debido a que no considera las deducciones hechas anteriormente totalmente válidas para el resto del razonamiento. Sin embargo, es necesario revisar las deducciones anteriormente hechas según vayan apareciendo nuevos cambios, por lo que el razonamiento predeterminado se convierte en una herramienta necesaria para casos donde toda la información no está disponible a tiempo o cuando es necesario un razonamiento de variada información simultáneamente.[4]

Diagramas basados en modelos causales

Los diagramas basados en modelos causales fueron desarrollados por Iri [16], los cuales son capaces de describir el comportamiento del sistema en términos de relaciones de causa-efecto entre las entidades del sistema siendo representadas mediante gráficos dirigidos.[17]

El diagnóstico, al revés de la simulación busca la deducción del modelo o estructura adecuada a un comportamiento específico, para lo cual necesita reflexionar acerca de las relaciones causa –efecto en el proceso. En los primeros principios de los métodos basados en el modelo, se comienza con la descripción de sistema con las observaciones

hechas sobre el mal funcionamiento del proceso. Luego, se procede al razonamiento de identificar los cambios funcionales que resultaron en el mal funcionamiento del proceso.

Las relaciones causa-efecto o los modelos pueden ser representados en la forma de gráficos con signo (SDG), siendo el diagrama un gráfico con arcos dirigidos entre los nodos, el SDG es un gráfico en donde los arcos dirigidos poseen un signo positivo o negativo agregado. Los arcos dirigidos conducen de los nodos 'de causa' a los nodos 'de efecto'. Cada nodo en el SDG corresponde a la desviación del estado estable de la variable. Los SDG tienen nodos que representan eventos o variables y bordes que representan las relaciones entre los nodos. Los SDG son más compactos que las tablas de verdad, las tablas de decisiones o los modelos de estado finito.[4]

Una gran innovación en los diagramas causales fueron las funciones de transferencia lineales con elementos acertivos (*QTF*) por Leyval [18], por lo cuál era necesario nuevos métodos de razonamiento basados en residuos. Uno de ellos, las ecuaciones de diferencia algebraica por Montmain & Gentail [19], los cuáles permitían un mejoramiento de los resultados de diagnóstico siendo capaces de detectar diferentes tipos de fallas, como sensores, actuadores y fallas de proceso.

Sin embargo, la habilidad de este método en detección de fallas es limitada, el método asume que una falla primaria es un cambio en una variable (representada por un nodo en el diagrama) en vez de un cambio en la consistencia entre las variables (representada como un arco en el diagrama). En la industria se busca conocer el componente del proceso que causa la falla, pero esto sólo es aplicable para fallas de lectura, debido a que los nodos en el diagrama del modelo representan el sensor del proceso, mientras que los nodos solos que representan fallas no puede proveer suficiente información para identificar los arcos en el diagrama.[17]

Árbol de fallas

Los Arboles de Fallas son usados para analizar la fiabilidad y seguridad de los sistemas, fue desarrollado por los laboratorios Bell en 1961. Un árbol de fallas es un árbol lógico que propaga acontecimientos primarios o defectos al acontecimiento de nivel superior. Cada árbol usualmente tiene capas de nodos, y en cada nodo son desarrolladas operaciones lógicas para la propagación.[4]

El análisis del árbol de fallas consiste en 4 etapas: definición del sistema, construcción del árbol de fallas, evaluación cualitativa y evaluación cuantitativa. La creación de árbol de fallas se produce analizando las causas que provocarían un evento de mayor nivel, conectándose mediante nodos, así se expande el árbol hasta encontrar un elemento primario o elemental. Luego de la construcción, se procede a la evaluación cualitativa que busca el desarrollo de una mínima colección de fallas primarias que son necesarias y suficientes para causar una falla de sistema, con lo que podemos identificar las fallas críticas de los componentes[20]. Para la evaluación cuantitativa, el conocimiento sobre la probabilidad de la ocurrencia de los eventos primarios es usado para calcular la probabilidad de fallas de los eventos de nivel más elevado.

El árbol de fallas provee un significado computacional de las combinaciones lógicas para analizar las fallas de sistemas. Dichas combinaciones lógicas (OR, AND, XOR) ayudan a reducir las falsas soluciones y la representación del sistema.

El problema más grande con árboles de fallas, es que el desarrollo es propenso a errores en etapas diferentes, por lo que dependen de la persona que creó el modelo mental y no hay ningún método formal de verificar la exactitud del árbol de fallas desarrollado. Para realizar el diagnóstico constante de árboles de fallas, los árboles comprensivamente deben representar el proceso mediante relaciones causales que expliquen todas las razones de fallas.[4]

Física Cualitativa

El conocimiento de física cualitativo en el diagnóstico de fallas, ha sido representado en dos caminos. El primer acercamiento es sacar ecuaciones cualitativas de las ecuaciones diferenciales llamadas ecuaciones de confluencia. Un factor importante de notar, consiste en que el comportamiento cualitativo puede ser sacado incluso si un modelo matemático exacto no puede ser desarrollado. Los modelos cualitativos no requieren información detallada tales como expresiones exactas y valores numéricos sobre el proceso. La información de la magnitud sobre los valores normales de operaciones de parámetros de proceso y variables es a menudo suficiente.[4]

Un método existente, fue el método de ordenamiento causal, que es usado para conseguir las relaciones causales por una reducción conveniente de las relaciones funcionales conocidas del proceso[21]. El método de ordenamiento causal establece a priori al diagnóstico, un ordenamiento parcial o completo entre las variables en un sistema de ecuaciones. Existe otro método, llamado ordenamiento de preferencia, que ha sido usado para ordenar las variables del punto de vista de flujo de la información entre ellos.

La idea central es que el flujo de la información entre estas ecuaciones no es simultáneo un reconocimiento de la presencia de asimetría (el orden de preferencia parcial o completa entre las variables) en las ecuaciones. Esta asimetría muestra los canales de flujo de la información y así representa la causalidad.[4]

Otro acercamiento en la física cualitativa es la derivación de comportamiento cualitativo de las ecuaciones ordinarias diferenciales (ODEs). Estos comportamientos cualitativos de fallas diferentes pueden ser usados como una fuente de conocimiento. En Sacks[20], se examina las aproximaciones lineales de elementos acertados para ecuaciones no lineales diferenciales por el empleo de un razonamiento cualitativo matemático para deducir las propiedades cualitativas del sistema. En Kuipers[21], se predice el comportamiento cualitativo usando ecuaciones cualitativas diferenciales (QDEs) que es una abstracción de las ODEs que representan el estado del sistema.

Los objetivos de estas metodologías son de relacionar de descripciones cualitativas físicas y descripciones de ecuaciones a comportamientos cualitativos y proporcionar expli-

caciones del comportamiento, basado en observaciones de proceso y la descripción de sistema. La ventaja de estos simuladores cualitativos, es su capacidad de crear conclusiones parciales del conocimiento incompleto y a menudo de conocimiento incierto del proceso.[4]

Jerarquía de abstracción de conocimiento de proceso

Otra forma de modelar el conocimiento, es el desarrollo de jerarquías de abstracción basadas en la descomposición, la cual debe ser capaz de dibujar inferencias sobre el comportamiento del sistema total basándose únicamente de las leyes que gobiernan el comportamiento de sus subsistemas. En la descomposición, las leyes del subsistema no pueden suponer el funcionamiento del sistema entero. En una descripción jerárquica, una podría representar una descripción genérica de una clase de partes del proceso. Por lo cual las ecuaciones gobernantes que describen una clase entera de partes de proceso pueden hacer suposiciones sobre la clase como un todo, pero no pueden hacer ninguna suposición sobre el comportamiento de partes particulares del proceso.[21]

Otro principio importante para la descomposición de sistemas, es el principio de lugar: las leyes para una parte expresamente no pueden referirse a ninguna otra parte. El principio de lugar permite predecir el comportamiento basado sólo sobre la información local. Las descomposiciones del proceso de sistemas más comunes son las siguientes: estructural, la cual especifica la información de conectividad de una unidad y funcional, la cual especifica la salida de una unidad como una función de sus entradas y posiblemente de la información del estado. Dichas descomposiciones permiten una representación de la funcionalidad de un sistema en términos de relaciones de entrada-salida de sus partes o unidades, por lo cual no es determinante si fue hecho de forma cualitativa o cuantitativa.[4]

La descomposición de un proceso de un sistema a varios subsistemas puede ser desarrollada en varios niveles de abstracción. Existen 2 dimensiones en la cual la abstracción en diferentes niveles es posible, estructural y funcional. La jerarquía estructural representa la información de conectividad entre el sistema y sus subsistemas, mientras que la jerarquía de abstracción funcional representa las relaciones de significado-propósito entre un sistema y sus subsistemas.[22, 4]

La búsqueda funcional busca diagnosticar sistemas de procesos complejos que tienen subsistemas con las funciones específicas que son individualmente reconocibles en la respuesta de sistema total. Estos subsistemas son descritos en un nivel inferior como unidades de proceso, sensores, reguladores, actuadores y elementos de control. La idea central es que la falla del subsistema de nivel más alto nivel es debido a la falla del mal funcionamiento de una o varias de estas unidades y utilizar esta descripción del nivel más alto para rápidamente identificar el subsistema que es la fuente de ese mal funcionamiento. Debido a ello, este método tiene la virtud de evitar el detalle innecesario en las tempranas etapas de diagnóstico y rápidamente enfocar a las áreas del problema.[22]

1.3.5. Método a emplear

Para el desarrollo de la presente tesis, se utilizó el Filtro de Kalman como un observador de estado, debido principalmente a ser un método extensamente aplicado en sistemas de navegación, y control aeroespacial, entre otros. Es aplicable a sistemas lineales como el motor de corriente continua estudiado, así mismo el filtro de Kalman minimiza el error de estimación ante ruidos gaussianos y genera el parámetro innovación el cual provee de las estadísticas necesarias para la correcta determinación de la falla.

1.4. Objetivos de la Tesis

1.4.1. Objetivo General

Diseñar un sistema de detección e identificación de fallas para un motor DC, basado en filtros de Kalman haciendo uso de simulaciones en el software Matlab para la identificación de fallas de sensor.

1.4.2. Objetivos Específicos

- Identificar el modelo del sistema del motor de corriente continua, mediante la metodología de Ziegler-Nichols en lazo abierto y confirmar su función de transferencia mediante la herramienta de Identificación de Sistemas de Matlab.
- Investigar sobre las metodologías para la detección y determinación de fallas (FDI).
- Diseñar el sistema de detección y determinación de fallas para el motor estudiado haciendo uso del filtro de Kalman.
- Realizar pruebas mediante el software Matlab sobre el sistema diseñado para comprobar su aplicabilidad al motor estudiado.

Capítulo 2

Detección de Fallas en Motores de Corriente continua

2.1. Características de los Motores de Corriente Continua

El motor de corriente continua o DC es una máquina eléctrica que transforma energía eléctrica en energía mecánica. El motor DC, así como el motor AC se basan en el principio de repulsión magnética, debido a las corrientes que circulan por las espiras, generando campos electromagnéticos y pares de fuerzas inducidas obligándolas a girar.

Las aplicaciones de los motores de corriente continua se han mantenido en aplicaciones especialmente en máquinas, herramientas y en procesos industriales. A pesar de las mejoras que han sido desarrolladas en su diseño, la máquina de corriente continua es constructivamente más compleja que las máquinas de corriente alterna debido al empleo de escobillas, colector, etc.

La complejidad del motor de corriente continua frente a las máquinas de corriente alterna, las convierte comparativamente en menos robusta, además requiere mayor mantenimiento y a la vez tiene un mayor volumen y peso para la generación de la misma potencia. No obstante, el motor DC. tiene múltiples aplicaciones, especialmente como motor, debido principalmente a:

- Amplio rango de velocidades (ajustables de modo continuo y controlable con alta precisión).
- Característica de torque-velocidad variable, constante o bien una combinación ideada por tramos.
- Rápida aceleración, desaceleración y cambio de sentido de giro.
- Posibilidad de frenado regenerativo.

Entre las grandes aplicaciones de los motores DC, encontramos los grandes motores de corriente continua, los cuales se utilizan en prensas de impresión, transporte de los ventiladores, bombas, elevadores, grúas, fábricas de papel, textiles, etc. Mientras

que, los pequeños motores de corriente continua, que están fraccionados en potencia, se utilizan en dispositivos de control tales como taco-generadores para sensores de velocidad y servomotores para el posicionamiento y seguimiento. [23]

2.2. Motor de Corriente Continua de excitación independiente

Entre las principales características de los motores DC de excitación independiente encontramos:

- Ambos bobinados del estator y rotor son excitados por corriente continua.
- El rotor tiene el colector o conmutador.
- El voltaje continuo a los devanados de armadura se suministra a través de los cepillos eléctricos que establecen contacto con el colector.
- Los cepillos se fijan en relación con el estator y se colocan para obtener un desfase angular específico.
- Para aprovechar al máximo el par electromagnético, los ejes magnéticos del estator y rotor están desfasados uno del otro en 90 grados mediante un colector

2.2.1. Modelo Matemático del Motor de Corriente continua de excitación independiente

Las ecuaciones dinámicas que describen el comportamiento del motor de corriente continua de excitación independiente, son:

$$V_a = R_a i_a + L_a \frac{di_a}{dt} + K_b i_f \omega_m \quad (2.1)$$

$$V_f = R_f i_f + L_f \frac{di_f}{dt} \quad (2.2)$$

Donde R_a es la resistencia de armadura, R_f es la resistencia de campo, i_f es la corriente de campo, i_a es la corriente de armadura, L_a es la inductancia de armadura, L_f es la inductancia de campo y ω_m la velocidad del motor.

Las ecuaciones están relacionadas con la operación de un motor conectado rígidamente a una carga con momento de inercia (J) y las pérdidas de fricción en la carga son representadas con un coeficiente viscoso (B), por lo que el torque desarrollado por el motor esta representado por la ecuación 2.3.

$$T_e = T_i + B\omega_m + J \frac{d\omega_m}{dt} \quad (2.3)$$

Donde ω_m es la velocidad angular, T_i es el torque de carga y $B\omega_m$ representa las pérdidas del torque rotacional en el sistema. Generalmente el torque es relacionado con la corriente de armadura (i_a) y con el flujo de campo (ϕ) mediante la ecuación 2.4[23]

$$T_e = K_a * \phi * i_a \quad (2.4)$$

Para un motor DC de excitación independiente el flujo de campo esta expresado por la ecuación 2.5.

$$\phi = \frac{N_f * i_f}{S} = K_f i_f \quad (2.5)$$

Donde N_f es el número de vueltas en el bobinado de campo y S es la reluctancia de la estructura. Uniendo las ecuaciones el torque generado queda expresado por la ecuación 2.6.

$$T_e = K_a * K_f * i_f * i_a \quad (2.6)$$

Denominaremos una constante $K_b = K_a * K_f$ y reemplazamos en la ecuación 2.6.

$$T_e = K_b * i_f * i_a \quad (2.7)$$

Definimos $K_m = K_b * i_f$ para una i_f constante, para simplificar las ecuaciones 2.4 , 2.3 y 2.1.[23]

$$T_e = K_m * i_a \quad (2.8)$$

$$V_a = R_a i_a + L_a \frac{di_a}{dt} + K_m \omega_m \quad (2.9)$$

$$K_m * i_a = T_i + B\omega_m + J \frac{d\omega_m}{dt} \quad (2.10)$$

2.3. Identificación del Sistema

Para la modelamiento del sistema estudiado, se ha considerado un sistema que consta de un actuador, el motor de corriente continua y el sensor de velocidad.

Siendo el actuador una fuente continua de voltaje variable que controla el voltaje de armadura del motor, específicamente esta formado por un medio puente de tiristores que son controlados mediante una salida analógica de la tarjeta de adquisición NI 6221 de 37 pines, para generar un voltaje continuo a partir de una fuente de voltaje alterna.

El sensor es la entrada del canal análogo de la tarjeta de adquisición de datos NI 6221 de 37 pines de la compañía National Instruments, la cual está conectada a un modulo de Lucas-Nülle el cual extrae los valores de velocidad del motor y los convierte a señales analógicas de rango de 0 a 10 voltios.

En la figura 2.1, se muestra las conexiones necesarias para poder efectuar una identificación del motor de corriente continua.

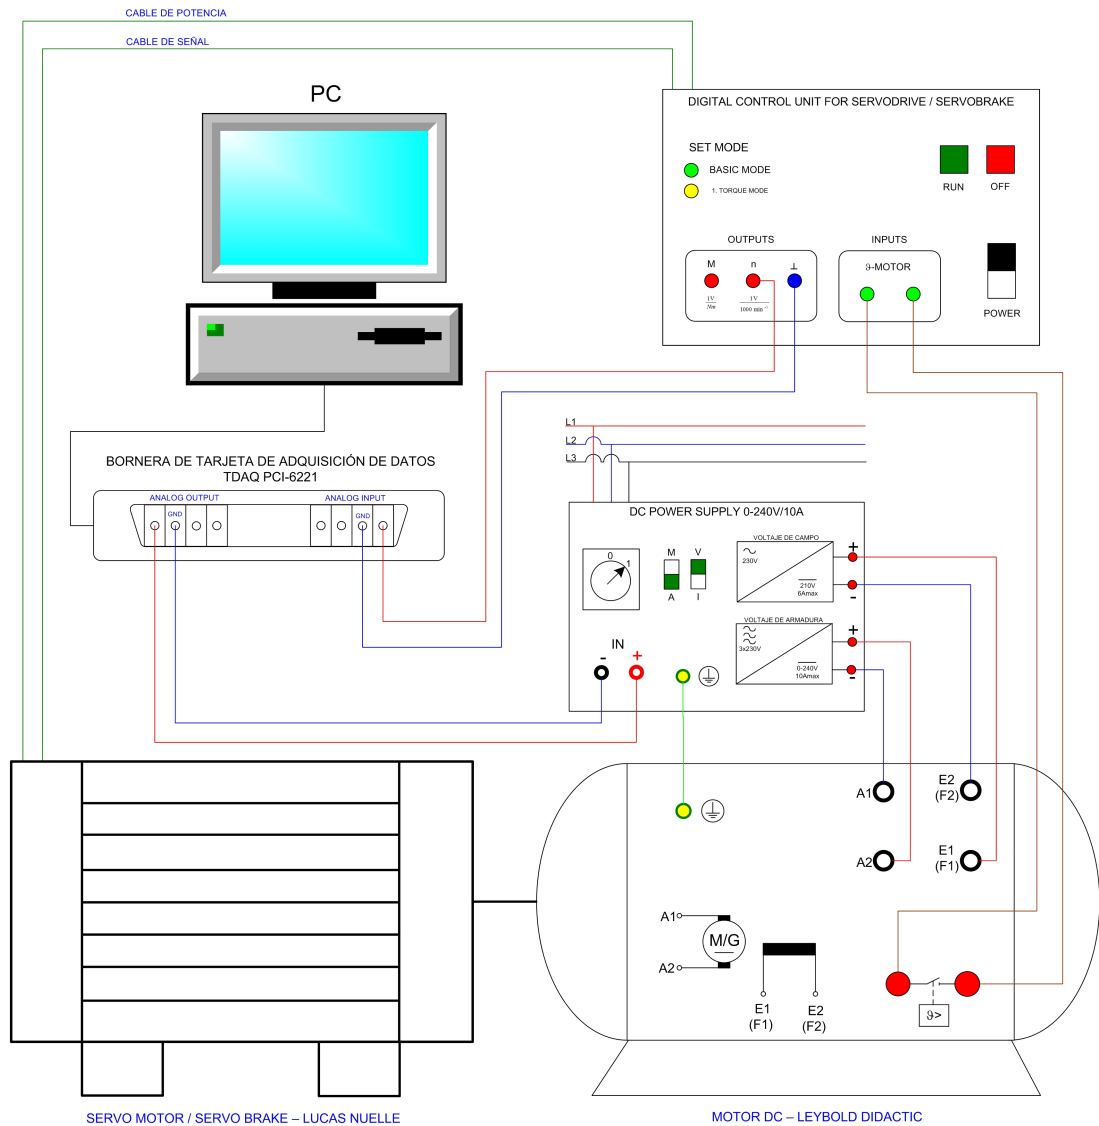


Figura 2.1: Conexiones del Motor DC

2.3.1. Método de Ziegler-Nichols en lazo abierto

Para la identificación del modelo del motor de corriente continua de excitación independiente, primero se deberá encontrar el rango lineal del modelo según la curva estática generada.

Posteriormente, según el rango lineal obtenido se realiza la prueba dinámica, donde se analiza la respuesta transitoria de la salida obtenida aplicando un escalón a la entrada

del sistema logrando determinar el comportamiento de la salida del sistema. A partir de su respuesta, se obtiene una función de transferencia de entrada y salida del modelo que se adecue a dicho comportamiento.

2.3.1.1. Prueba Estática

Para el desarrollo de la prueba estática se trabaja con la planta a lazo abierto como se muestra en la figura 2.2, en la cual vamos variando de forma gradual la entrada del sistema desde 0v hasta su máximo nivel de trabajo, en este caso es 10v; generando en la salida del sistema los datos `yout_escalon` para cada variación gradual de la entrada.

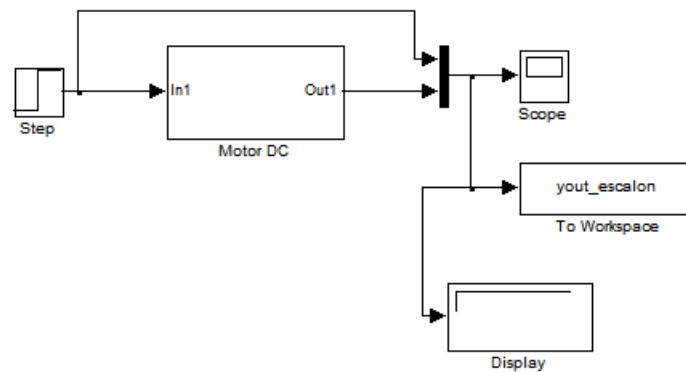


Figura 2.2: Herramienta de Simulación del Motor DC

Tomando ambos parámetros, la entrada al sistema representada por la señal "step" y la salida "yout_escalon" se forma una curva denominada curva estática. Esta curva estática, nos da el rango lineal o zona lineal de trabajo de la planta. Para nuestra prueba estática, la entrada step es la representación escalada del voltaje de armadura, la entrada al sistema varía de 0 a 10 VDC, siendo este rango la representación de la variación real del voltaje de armadura del motor. Y nuestra salida es la velocidad del motor, cuyo rango es de 0 a 2000 RPM aproximadamente.

En la figura 2.3, se muestra la curva estática del motor DC, cuyos resultados obtenidos muestran que el rango lineal del motor DC de excitación independiente fue de 0 a 2000 RPM, significando que en todo momento nuestra planta, el motor DC tiene un comportamiento lineal.

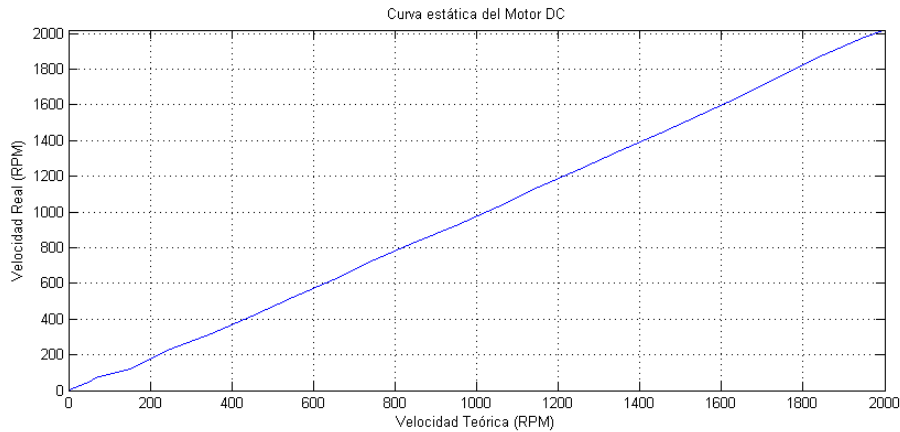


Figura 2.3: Curva estática del Motor DC

2.3.1.2. Prueba Dinámica

Posteriormente a la obtención del rango lineal de trabajo del motor DC, se desarrolla la prueba dinámica del motor. La cual se realiza a lazo abierto y su objetivo es encontrar el comportamiento dinámico del proceso mediante el análisis de la respuesta transitoria de la salida, que se obtiene al introducir una entrada tipo escalón del sistema. Para la realización de la prueba dinámica nos basaremos en el rango lineal obtenido de la curva estática, siendo este rango la medida del tamaño del escalón a la entrada del sistema para la generación de la respuesta transitoria del sistema. En la figura 2.4, se muestran la entrada al sistema tipo escalón y la respuesta transitoria del sistema obtenida a la salida.

Basándose en la respuesta transitoria del sistema, se determinará la función de transferencia del sistema.




Figura 2.4: Respuesta Transitoria ante entrada tipo escalón

2.3.1.3. Determinación de la Función de Transferencia

Del análisis de la respuesta transitoria de la salida ante una entrada tipo escalón se obtiene una aproximación de la función de transferencia del sistema que representa dicha

respuesta ante una misma entrada tipo escalón. Para lo cual se ha tomado 3 puntos en el tiempo de la curva generada. El primer punto es el origen del escalón denotado como t_0 , el segundo punto es el origen de la respuesta transitoria denotado como t_δ y el tercer punto, es el tiempo para el cual la medida de la respuesta transitoria sea el 63 % de la magnitud total del valor de establecimiento (2000 RPM), es decir el punto en el tiempo en el cual la salida del sistema tiene un valor 1260 RPM aproximadamente , siendo este punto denotado como t_{63} .

En la figura 2.5, se aprecia el retardo de la respuesta transitoria de la salida ante una entrada tipo escalón, en el cual se encuentra los puntos t_0 y t_δ , cuyos valores son 0.28 segundos y 0.4 segundos respectivamente. De su diferencia se obtiene el tiempo $\hat{\tau}$ para el modelamiento de la función de transferencia.

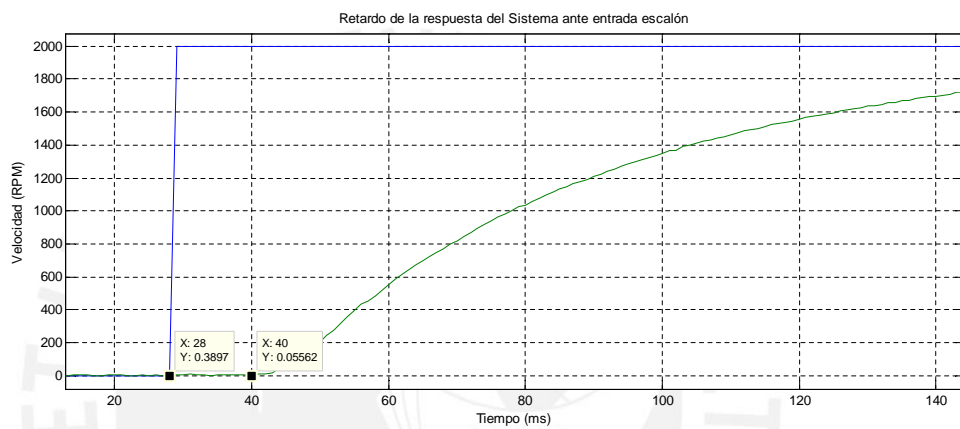


Figura 2.5: Retardo de la respuesta transitoria ante una entrada escalón

En la figura 2.6, se aprecia la diferencia de tiempo entre el punto t_{63} y el punto t_δ . De su diferencia se ha obtenido el tiempo \hat{T}_d para el modelamiento de la función de transferencia.

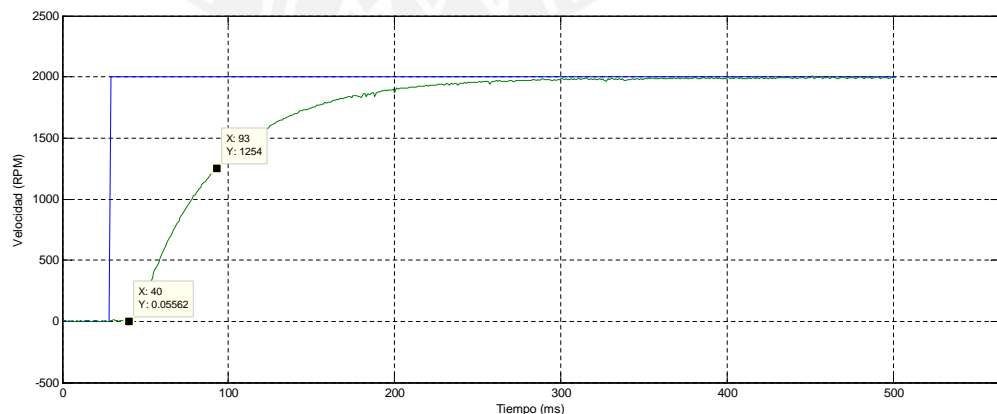


Figura 2.6: Punto t_{63}

Con la determinación de ambas diferencias de tiempo se procede a calcular la función de transferencia con las siguientes ecuaciones.[24]

$$\hat{k} = \frac{y_f - y_0}{u_f - u_0} \quad (2.11)$$

$$\hat{\tau} = t_{63} - t_\delta \quad (2.12)$$

$$\hat{T}_d = t_\delta - t_0 \quad (2.13)$$

$$\hat{G}(s) = \frac{\hat{k}}{\hat{\tau}s + 1} \exp(-\hat{T}_d s) \quad (2.14)$$

Debido al escalamiento de la entrada u para que se aprecie la llegada al punto final (*set point*), el valor real de u_f es aproximadamente 185 VDC. Es debido a ello, que en la función de transferencia se ve representado el voltaje de armadura del motor como parámetro de entrada y la velocidad como parámetro de salida.

Siendo el rango de variación del voltaje de armadura de 0 - 185 VDC y el rango de velocidad de 0 - 2000 RPM, se genera la función de transferencia aproximada.

$$G(s) = \frac{10,81}{0,53s + 1} \exp(-0,12s) \quad (2.15)$$

2.3.2. Identificación mediante la Herramienta de Identificación de Sistemas

El GUI es la interfaz gráfica de una herramienta del Matlab denominada Identificación de Sistemas, la cual permite identificar sistemas hasta de tercer orden, en los cuales puede ocurrir retardos, además de permitir la inclusión de un cero y un integrador al sistema de ser requerido para poder determinar con mayor precisión el modelo. Siendo la precisión del modelo determinada por la misma herramienta según la función de transferencia obtenida y los datos ingresados.

Mediante este método de corroboración, se logra calcular de forma más precisa la función de transferencia que corresponde según la respuesta transitoria de la salida ante una entrada tipo escalón. Para determinar la función de transferencia, la herramienta de identificación de sistemas minimiza la diferencia entre la salida teórica del modelo y la salida medida en cada instante. El criterio de minimización es una norma ponderada de los errores obtenidos en cada instante de tiempo. Para ello se ha tomado los datos de la respuesta transitoria obtenida de manera experimental, para comprobar los resultados obtenidos anteriormente, generando los siguientes resultados.[25]

2.3.2.1. Aproximación del Modelo a un Sistema de Primer orden con retardo

En la figura 2.7, mediante la interfaz gráfica de la herramienta de Identificación de sistemas podemos escoger las características de la función a aproximar según los datos obtenidos de entrada y salida. Para nuestro caso, se aproxima primero a un modelo de primer orden con retardo y los resultados se muestran en las figuras 2.8 y 2.9 .

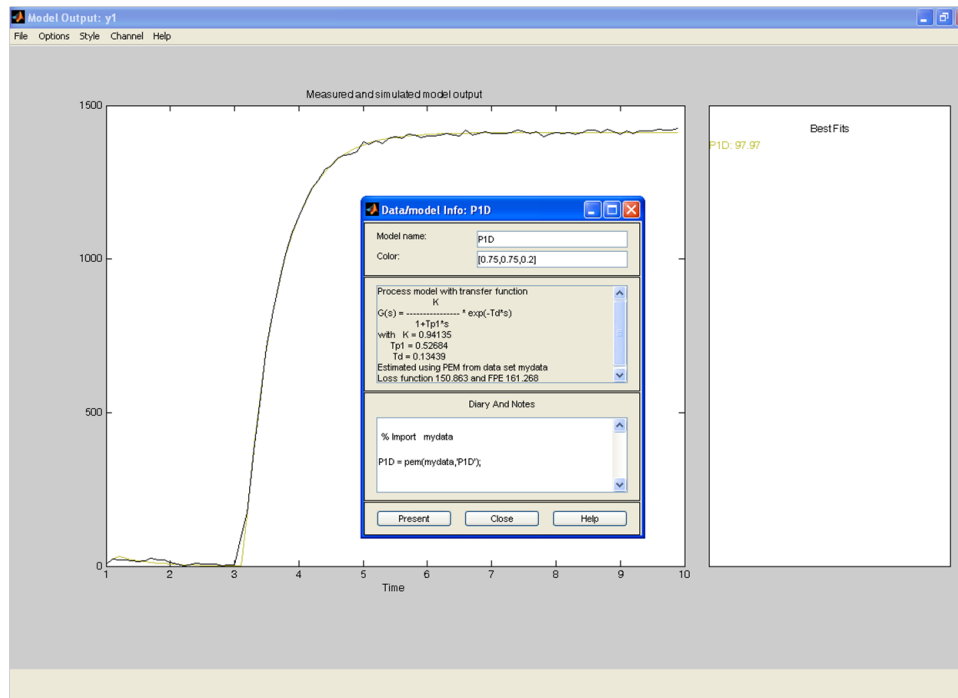


Figura 2.7: Modelamiento de la Respuesta Transitoria Modelo del Proceso a una función de primer orden

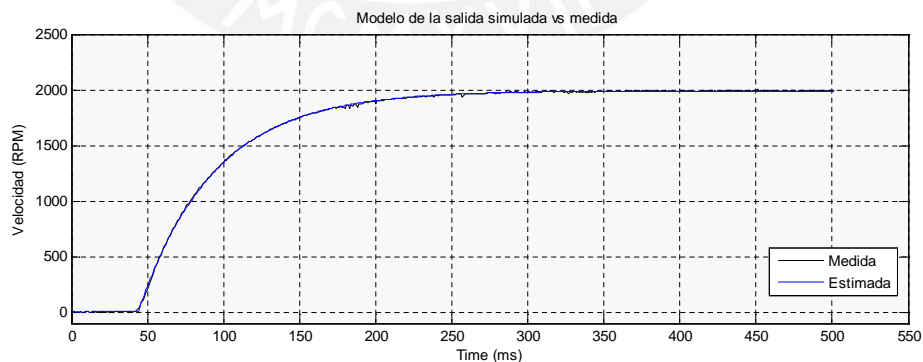


Figura 2.8: Aproximación del sistema una función de Primer orden con retardo




Figura 2.9: Respuesta transitoria del sistema ante una entrada tipo escalón

De los resultados obtenidos mediante la herramienta, se obtuvo un índice de adecuación o porcentaje de aproximación proporcionado por la herramienta de 98.91 % de la respuesta transitoria en la salida ante una entrada tipo escalón generada por la función de transferencia aproximada para un sistema de primer orden con retardo. Además de contar con un elevado índice de adecuación también existe una notoria similitud gráfica de ambas respuestas.

A partir de la estimación del sistema a una función de transferencia de primer orden con retardo se encontró la siguiente función de transferencia aproximada:

$$G(s) = \frac{10,7}{0,499s + 1} \exp(-0,1476s) \quad (2.16)$$

2.3.2.2. Aproximación del Modelo a un Sistema de Segundo orden con retardo

En la figura 2.10 se muestra la selección del modelo a aproximar, basándose en la respuesta transitoria de la salida ante una entrada tipo escalón. Generándose un modelo de segundo orden con retardo, cuyos resultados de la aproximación se muestran en la figura 2.11.

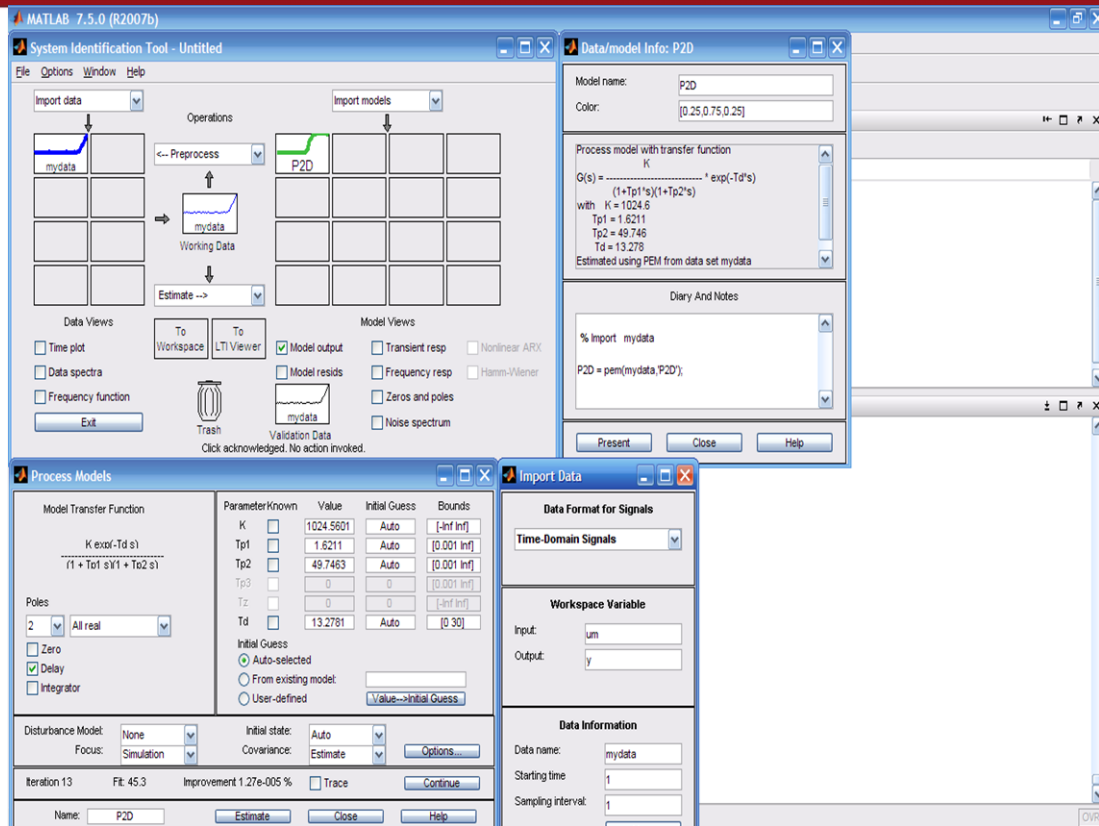


Figura 2.10: Modelamiento de la respuesta transitoria del proceso a una función de segundo orden




Figura 2.11: Aproximación del sistema a una función de Segundo orden con retardo

De los resultados obtenidos mediante la herramienta de identificación, se obtuvo un índice de adecuación o porcentaje de aproximación proporcionado por la herramienta de identificación de 83.76 % para la respuesta transitoria en la salida ante una entrada tipo escalón generada por la función de transferencia aproximada para un sistema de segundo orden con retardo. Dicho índice es inferior en comparación al obtenido en la estimación del sistema para una función de primer orden, así mismo existe una falta de similitud gráfica entre la respuesta real y la estimada.

Apartir de la aproximación del sistema a una función de transferencia de segundo orden se obtiene la siguiente función de transferencia:

$$G(s) = \frac{10,736}{(0,46063s + 1)(0,45901s + 1)} \exp(-0,11807s) \quad (2.17)$$

2.3.2.3. Aproximación del Modelo a un Sistema de Segundo orden con retardo y un cero.

En la figura 2.12, se muestra la selección de un modelo de segundo orden con un cero y retardo, al cual se va a estimar la respuesta transitoria de la salida ante una entrada tipo escalón. Generándose los siguientes resultados de la aproximación, los cuales se muestran en las figuras 2.12, 2.13 y 2.14.

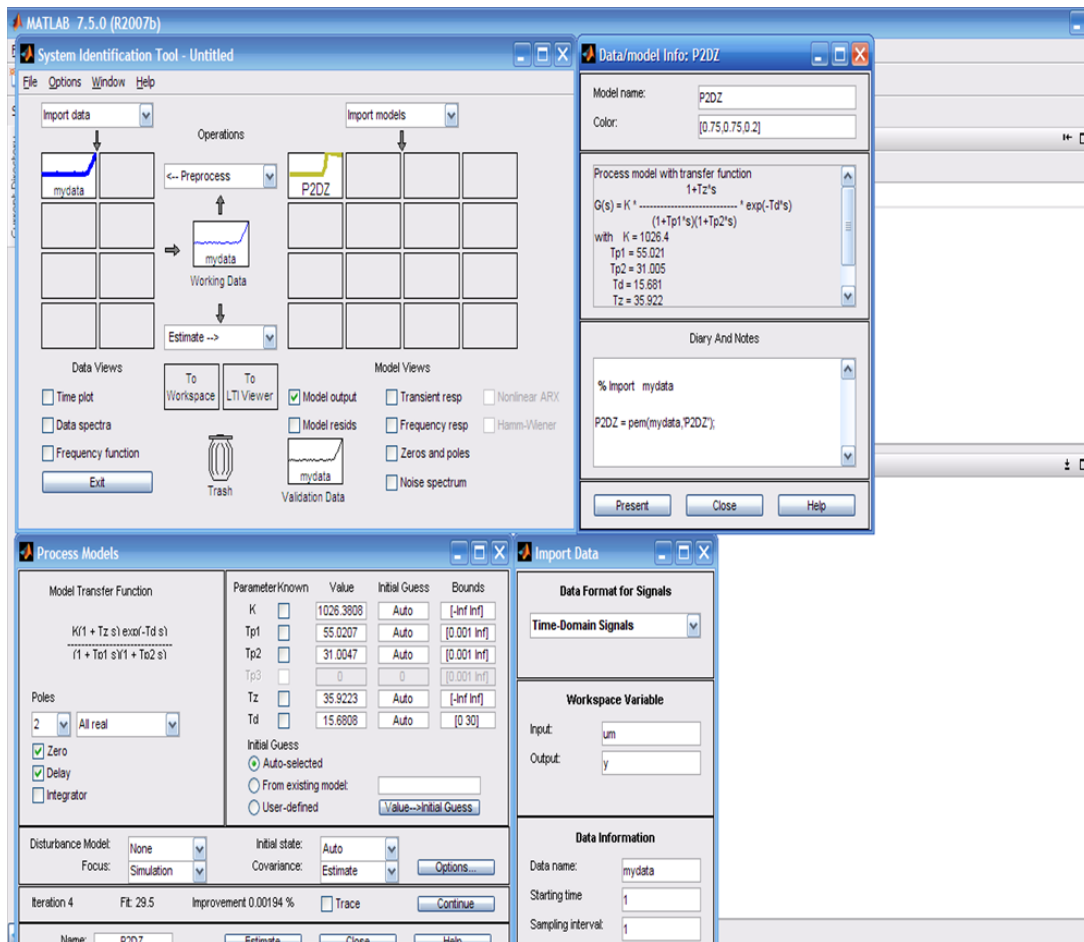


Figura 2.12: Modelamiento de la respuesta transitoria del proceso a una función de segundo orden con un cero




Figura 2.13: Aproximación del sistema a una función de segundo orden con retardo y un cero




Figura 2.14: Respuesta transitoria ante entrada escalón real y la estimada

De los resultados, se obtuvo un índice de adecuación o porcentaje de aproximación proporcionado por la herramienta de identificación de 99.12% para una función de transferencia de segundo orden con cero, la cual relaciona la respuesta transitoria en la salida con su entrada tipo escalón. Dicho índice de adecuación, es el más elevado obtenido, así mismo existe una notoria similitud gráfica entre la respuesta real del sistema y la respuesta estimada. Generándose a partir de la aproximación, la siguiente función de transferencia aproximada:

$$G(s) = \frac{10,77(0,35923s + 1)}{(0,55021s + 1)(0,31005s + 1)} \exp(-0,15681s) \quad (2.18)$$

2.3.2.4. Modelo del motor DC a emplear

Para el diseño del sistema de identificación de fallas, se seleccionó la función de transferencia de segundo orden y un cero mostrada en la ecuación 2.19, debido a tener un índice de adecuación del 99.12% cuyo valor es mayor en comparación con los demás índices obtenidos, 83.76% y 97.97%, para los modelos de segundo orden y primer orden respectivamente, obtenidos mediante la herramienta de identificación de sistemas.

$$G(s) = \frac{10,77(0,35923s + 1)}{(0,55021s + 1)(0,31005s + 1)} \exp(-0,15681s) \quad (2.19)$$

2.4. Escenario de Fallas

Los orígenes de las fallas en cualquier planta o proceso son diversos, lo mismo ocurre en un motor de corriente continua. Entre los principales orígenes encontramos las fallas estructurales, que ocurren debido principalmente a la acción del contacto entre elementos propios del motor así como mala ubicación de elementos del motor, como inclinación del eje del motor o mal posicionamiento del colector, generándose un desgaste continuo con el uso. Un ejemplo adecuado de falla estructural sería el desgaste en las escobillas, al estar en contacto permanente con el colector tienen un desgaste más perceptible en tiempos cortos, lo cual genera fallas como cortocircuito en el colector. Pero las fallas estructurales no solamente son internas, sino también se consideran las fallas del controlador o ley de control que determina su correcto funcionamiento, un ejemplo sería un control de velocidad de un motor, en el cual se pueden manifestar fallas debido a errores humanos o problemas internos del controlador, lo que originan un mal funcionamiento general del motor.

Además de las fallas estructurales, encontramos las fallas aditivas por lectura de los sensores, para el caso del motor de corriente continua sería la lectura de velocidad mediante un tacómetro u otro elemento de lectura de velocidad, debido que al ser elementos los cuales se gastan con el transcurso del tiempo debido a rozamiento de componentes internos, generan lecturas erróneas que conllevan a la aplicación de una incorrecta ley de control u otra acción que modifica el correcto comportamiento del motor.

Así mismo, encontramos fallas aditivas en el actuador, por ejemplo entre los principales actuadores en plantas industriales, encontramos gruas, montacargas, compresores y como unidades de emergencia o de espera que requieren de servicios de baterías energía de reserva para obtener una alta fiabilidad.

Para ejemplificar un caso de falla en el actuador en un motor de corriente continua, se considera a una faja transportadora, la cual falla debido a problemas de rodamientos, haciendo que la velocidad de trabajo normal disminuya, por consiguiente la ley de control se ve modificada generándose una alteración al trabajo normal del motor el cual puede sobrepasar las características máximas de trabajo del motor, conllevando a fallas internas del motor.[26]

Fallas a detectar e identificar

En el desarrollo de la presente tesis, se ha considerado analizar las fallas aditivas presentes en el sensor del sistema del modelo lineal e invariante en el tiempo del sistema obtenido, el cual está compuesto por el motor de corriente continua de excitación independiente, su actuador y sensor. Por ello el sistema de detección a diseñar analizará la presencia de sólo una falla a la vez durante el desarrollo o ejecución del sistema.

Entre las fallas aditivas a considerar se encuentran las fallas tipo escalón y tipo rampa, las cuales son representadas como una entrada desconocida en el sistema.

Así mismo, una perturbación es también una entrada desconocida actuante en la planta, por ello físicamente no existe diferencia entre una perturbación y una falla aditiva certera. La distinción es más bien subjetiva, debido a que ante una entrada aditiva desconocida, se considera como falla aditiva a las entradas cuya presencia queremos detectar e identificar. Sin embargo, se considera como perturbaciones a aquellas entradas que deseamos ignorar y que el sistema no sea afectado por ellas. Considerando de esta manera una falla aditiva como una perturbación que deseamos detectar e identificar.[27]



Capítulo 3

Diseño de un sistema de Detección y Aislamiento de fallas

3.1. Filtro de Kalman

En 1960, R.E. Kalman publicó un artículo describiendo un método recursivo de solución para problemas de filtrado lineal en datos discretos. Desde ese momento, debido principalmente a los avances tecnológicos en el procesamiento digital, el filtro de Kalman ha sido sujeto de extensas investigaciones y aplicaciones, particularmente en el área de navegación autónoma o asistida.[28]

En forma teórica, un filtro de Kalman es una herramienta que puede estimar las variables en un buen rango del proceso. En términos matemáticos, el filtro de Kalman estima de forma precisa los estados en sistemas dinámicos lineales. El filtro de Kalman es un estimador estadísticamente óptimo con respecto de cualquier función cuadrática de error de estimación.

En la figura 3.1, se muestra el proceso de estimación del filtro de Kalman para un proceso lineal.




Figura 3.1: Dinámica de ciclos de predicción consecutiva y filtrado en Filtros de Kalman [3]

El filtro de Kalman no sólo funciona bien en práctica, también teóricamente es atractivo porque se puede demostrar que de todos los posibles filtros, es el que mejor minimiza la varianza de la estimación del error. Los filtros de Kalman suelen aplicarse en los sistemas de control embebidos porque al controlar un proceso, como paso previo se requiere una estimación precisa de las variables del proceso.[28]

3.1.1. El Filtro de Kalman Discreto

El proceso a estimar

El filtro de Kalman apunta a resolver el problema general de estimar el estado $x \in \mathbb{R}^n$ de un proceso controlado discreto el cual es gobernado por una ecuación lineal estocástica diferencial.

$$x_k = Fx_{k-1} + Gu + w_{k-1} \quad (3.1)$$

con una lectura de estado $y \in \mathbb{R}^m$

$$y_k = Hx_k + v_k \quad (3.2)$$

donde las variables aleatorias w_k y v_k representan el ruido de proceso y el ruido de lectura respectivamente. Ambos ruidos son asumidos como ruidos blancos gaussianos e independientes uno del otro.

$$p(w) \sim N(0, Q) \quad (3.3)$$

$$p(v) \sim N(0, R) \quad (3.4)$$

La matriz de F de dimensiones $n \times n$ en la ecuación 3.1 describe el estado anterior en el tiempo $k - 1$ con respecto al estado actual k , la matriz G de dimensiones $n \times 1$ describe la entrada control opcional $u \in \mathbb{R}^1$ para el estado x y la matriz H de dimensiones $m \times n$ en la ecuación de lectura 3.2 describe el estado de la lectura de y_k . [29, 28]

Origen computacional del filtro

Definimos x como la estimación previa del estado al tiempo k teniendo conocimiento del proceso previo al tiempo k , y la estimación posterior del estado dado la lectura y_k . Podemos definir un error de estimación tanto previo como posterior de la siguiente manera:

error de estimación previo:

$$e_k^- = X_k - \hat{X}_{k|k-1} \quad (3.5)$$

error de estimación posterior:

$$e_k = X_k - \hat{X}_{k|k} \quad (3.6)$$

La covarianza del error de estimación previo esta definida como

$$P_{k|k-1} = E \left[e_k^- e_k^{-T} \right] \quad (3.7)$$

y la covarianza del error de estimación posterior esta definida como

$$P_k = E \left[e_k e_k^T \right] \quad (3.8)$$

En las derivadas de las ecuaciones para el filtro de Kalman, se busca encontrar una ecuación que calcula una estimación posterior de estado \hat{X}_k como una combinación lineal de una estimación previa $\hat{X}_{k|k-1}$ y una diferencia ponderada entre una medición actual y_k y una medida de la predicción $H\hat{X}_{k|k-1}$ se muestra en la ecuación 3.9

$$\hat{X}_{k|k} = \hat{X}_{k|k-1} + K \left(y_k - H\hat{X}_{k|k-1} \right) \quad (3.9)$$

La diferencia $(y_k - H\hat{x}_k^-)$ en la ecuación 3.9 es llamada la innovación de la lectura, o el residuo. El residuo refleja la discrepancia entre la medición prevista $H\hat{x}_k^-$ y la actual lectura y_k . Un residuo de cero significa que ambas estan en completo acuerdo.[29, 28]

La matriz K de dimensiones $n \times m$ en la ecuación 3.9 es elegida para ser la ganancia o mezcla de factores que minimiza la covarianza posterior del error P_k mostrada en la ecuación 3.9. La minimización puede ser realizada sustituyendo la ecuación 3.9 en la definición del error e_k , sustituyendolo en la ecuación 3.8, posteriormente tomando la derivada con respecto a K e igualandola a cero, y entonces generándose la solución para K.

Una de las formas que minimiza K esta dada por

$$K_K = P_{k|k-1} H^T \left(H P_{k|k-1} H^T + R \right)^{-1} \quad (3.10)$$

De la función de K, se puede apreciar que cuando la covarianza del error de lectura se acerca a cero ($R \rightarrow 0$), la ganancia K_k tiende a H^{-1} .

$$\lim_{R_{k \rightarrow 0}} K_k = H^{-1} \quad (3.11)$$

De otro lado, cuando la covarianza del error de estimación previo se acerca a cero ($P_{k|k-1} \rightarrow 0$), la ganancia K_k tiende a cero.

$$\lim_{P_{k \rightarrow 0}^-} K_k = 0 \quad (3.12)$$

Otra forma de entender el valor de la ganancia K_k es que mientras la covarianza del error de lectura R se acerca a 0, la lectura actual y_k se vuelve mas confiable, mientras que la lectura de medición prevista $H\hat{X}_{k|k-1}$ es cada vez menos confiable. De otro lado,

cuando la covarianza del error de estimación previo $P_{k|k-1}$ se acerca a cero, la lectura actual y_k se vuelve cada vez menos confiable, mientras que la lectura de medición prevista $H\hat{X}_{k|k-1}$ es cada vez mas confiable.[29, 28]

El modelamiento del filtro de Kalman en un modelo de espacio estado en el cual se considera la entrada U_k se representa mediante las siguientes ecuaciones:

$$\hat{X}_{k+1|k} = F\hat{X}_{k|k} + GU_k \quad (3.13)$$

$$\hat{X}_{k|k} = \hat{X}_{k|k-1} + K_k\varepsilon_k \quad (3.14)$$

$$\varepsilon_k = Y_k - H\hat{X}_{k|k-1} - JU_k \quad (3.15)$$

donde K_k es la ganancia de Kalman, que proviene matemáticamente de la covarianza de la estimación del error $P_{k|k-1}$ y la covarianza de la innovación o residuo Σ_k y es dado de la siguiente manera:

$$K_k = P_{k|k-1}H^T\Sigma_k^{-1} \quad (3.16)$$

$$P_{k|k-1} = FP_{k|k}F^T + Q \quad (3.17)$$

$$P_{k|k} = (I_n - K_kH)P_{k|k-1} \quad (3.18)$$

$$\Sigma_k = HP_{k|k-1}H^T + R \quad (3.19)$$

Estas formulas pueden ser demostradas por inducción usando la distribución condicional de $(X_{k+1}^T, Y_k^T)^T$ dadas las observaciones pasadas y_1^{k-1} . Siendo la innovación ortogonal a las observaciones pasadas, es decir: [29, 28]

$$E(\varepsilon_k|y_1^{k-1}) = 0 \quad (3.20)$$

3.1.1.1. Estabilidad del Filtro de Kalman

El tiempo de invarianza asintótica y la estabilidad del filtro de Kalman son importantes para las aplicaciones, además de ser utilizado en el cálculo de la función de verosimilitud de las observaciones en un modelo de estado-espacio.

Debido a las ecuaciones, el filtro de Kalman se puede resumir como:[29, 28]

$$\hat{X}_{k+1|k} = \bar{F}\hat{X}_{k|k} + GU_k + FK_kY_k \quad (3.21)$$

$$\bar{F}_k = F(I_n - K_kH)$$

$$K_k = P_{k|k-1} H^T (H P_{k|k-1} H^T + R)^{-1}$$

Suponiendo que el error de covarianza $P_{k|k-1}$ converge a un estado de equilibrio cuyo valor es P , donde P es la solución de la llamada ecuación algebraica Riccati:

$$P - F P F^T + F P H^T (H P H^T + R)^{-1} H P F^T - Q = 0 \quad (3.22)$$

Suponemos aquí que $H P H^T + R$ es invertible; las condiciones suficientes para ello son: R no singular, o P no singular y H es de un rango completo. En este caso, la matriz del filtro en estado de transición F_k y la ganancia Kalman K_k también convergen a los valores de estado estable \bar{F} y K , dados por:

$$\bar{F} = F(I_n - KH) \quad (3.23)$$

$$K = P H^T (H P H^T + R)^{-1}$$

Una solución real positiva, simétrica, semidefinida de la ecuación algebraica de Riccati 3.22 se dice que es una fuerte solución si la correspondiente matriz de transición de estado del filtro H tiene todos sus autovalores dentro o sobre el círculo unitario. [29, 28]

Ahora P_s es una fuerte solución única de la ecuación 3.22 y también K_s y F sean las correspondientes ganancia y matriz de transición de estado del filtro en estado estable dados por la ecuación 3.23, dando el siguiente resultado:

Teorema de Estabilidad: Dada la condición de que (H, F) es observable y $(P_0 - P_s) > 0$ o $P_0 = P_s$, entonces

$$\lim_{k \rightarrow \infty} P_{k|k-1} = P_s \quad (3.24)$$

$$\lim_{k \rightarrow \infty} K_k = K_s$$

$$\lim_{k \rightarrow \infty} \bar{F}_k = \bar{F}_s$$

Note que si $Q = DD^T$, y si (F, D) tienen modos incontrolables en el círculo unitario luego F_s tendrá las mismas raíces en el círculo unitario, pero la convergencia y estabilidad del filtro de Kalman se mantienen asegurados en este caso. [29, 28]

Función de Probabilidad:

La función de probabilidad de una secuencia de observaciones gaussianas Y_1, \dots, Y_N , modelado por el modelo de estado-espacio. La probabilidad de las observaciones es la probabilidad de las innovaciones, dado que la secuencia del parámetro innovación es también un proceso Gaussiano, entonces tenemos:

$$-2l_N = \sum_{k=1}^N \left[\ln(\det \Sigma_k) + \varepsilon_k \Sigma_k^{-1} \varepsilon_k^T \right] \quad (3.25)$$

el cual asintóticamente para un N grande se conviene en:

$$-2l_N = N \ln \det(HPH^T + R) + \text{trace} \left[(HPH^T + R)^{-1} \sum_{k=1}^N \varepsilon_k \varepsilon_k^T \right] \quad (3.26)$$

donde P es el estado de equilibrio de la solución de la ecuación 3.22.[29, 28]

3.1.2. Modelo gráfico del Filtro de Kalman

Teniendo en cuenta las ecuaciones del Filtro de Kalman, se presenta en la figura 3.2, un diagrama del procesamiento de las matrices para el filtro de Kalman.

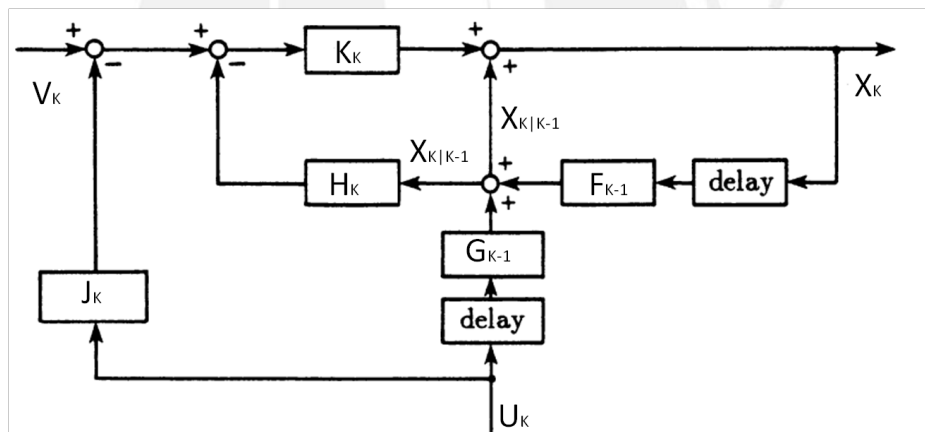


Figura 3.2: Modelamiento del Filtro de Kalman[5]

3.2. Cambios Aditivos en Modelos Lineales

Los cambios aditivos considerados, son cambios que son sumados a las ecuaciones del modelo lineal invariante en el tiempo, es por ello que son básicamente cambios en el valor medio de la distribución de las señales observadas. Precisando, se considera a $(Y_k)_{1 \leq k \leq n}$ una secuencia de observaciones con dimension r .

Los cambios aditivos pueden ser representados de diferentes maneras, según el modelo lineal seleccionado, entre los cuales tenemos: cambios en modelos ARMA, cambios en modelos de regresión, cambios en modelos de estado-espacio, etc.

En un proceso físico, las fallas aditivas se asocian generalmente a desviaciones en las mediciones de sensores o actuadores, mientras que las fallas multiplicativas se asocian a averías de componentes, fallas en la escala de sensores o la variación de parámetros físicos del proceso.[5]

3.2.1. Cambios Aditivos en Modelos de estado espacio

Se considera el sistema lineal dinámico descrito mediante una representación de estado espacio de las señales observadas $(Y_k)_k$

$$X_{k+1} = FX_k + GU_k + W_k \quad (3.27)$$

$$Y_k = HX_k + JU_k + V_k \quad (3.28)$$

donde el estado X , las lecturas Y y el control U tienen dimensiones n , r y m respectivamente, y donde $(W_k)_k$ y $(V_k)_k$ son dos ruidos blancos gaussianos e independientes, con matrices de covarianza Q y R respectivamente.

Los cambios aditivos sucitados en un tiempo desconocido t_0 pueden ser formalmente definidos de la siguiente manera:

$$X_{k+1} = FX_k + GU_k + W_k + \Gamma\Upsilon_x(k, t_0) \quad (3.29)$$

$$Y_k = HX_k + JU_k + V_k + \Xi\Upsilon_y(k, t_0) \quad (3.30)$$

donde Γ y Ξ son matrices de dimensiones $n \times \tilde{n}$ y $r \times \tilde{r}$ respectivamente, y donde $\Upsilon_x(k, t_0)$ y $\Upsilon_y(k, t_0)$ son los perfiles dinámicos de los cambios asumidos de dimensiones $\tilde{n} \leq n$ y $\tilde{r} \leq r$ respectivamente. Estas matrices y perfiles no son necesariamente completamente conocidos de antemano. El instante t_0 es el cambio desconocido en el tiempo, por lo cual $\Upsilon_x(k, t_0) = \Upsilon_y(k, t_0) = 0$ para $k < t_0$

Los cambios aditivos en un modelo de estado espacio, pueden ser representados mediante la figura 3.3




Figura 3.3: Cambios aditivos en un modelo de estado espacio[5]

Para obtener las ecuaciones recursivas y fórmulas explícitas, para el perfil dinámico de la marca del cambio en la innovación en el caso general. Donde la innovación es la salida el filtro de Kalman correspondiente al modelo sin cambio. Según la terminología usada para determinar las ecuaciones del filtro de Kalman, esta salida del proceso es exactamente la innovación del proceso antes del cambio y es el residuo después del cambio en el proceso.[5]

Al igual que en el filtro de Kalman, la estimación del estado x se puede resumir de la siguiente manera. De un paso por delante de predicción, la innovación ε_k y la estimación de estado se dan en las ecuaciones 3.13, 3.14 y 3.15 mientras que la ganancia de Kalman K_k , el estado de error de estimación de covarianzas $P_{k|k}$, y la covarianza de la innovación Σ_k se dan en las ecuaciones 3.16, 3.17, 3.18 y 3.19. La función lineal del modelo está expresada en las ecuaciones 3.27, 3.28 y el efecto aditivo del cambio $\Xi\Upsilon_y, \Gamma\Upsilon_x$ en las ecuaciones 3.29 y tras llevar a la descomposición del estado, su estimación, y la innovación:

$$X_k = X_k^0 + \alpha(k, t_0) \tag{3.31}$$

$$\hat{X}_{k|k} = \hat{X}_{k|k}^0 + \beta(k, t_0)$$

$$\varepsilon_k = \varepsilon_k^0 + \rho(k, t_0)$$

donde el exponente 0 es por las cantidades correspondientes al modelo que no ha cambiado 3.27 , 3.28 donde el último término de cada ecuación representa el efecto del cambio $\Xi\Upsilon_y, \Gamma\Upsilon_x$, el cual ocurre a un tiempo $t_0 \leq k$. Las funciones α, β y ρ son pre procesados con la ayuda de las siguientes recurrencias:

$$\alpha(k, t_0) = F\alpha(k - 1, t_0) + \Gamma\Upsilon_x(k - 1, t_0) \tag{3.32}$$

$$\beta(k, t_0) = (I - K_k H) F \beta(k - 1, t_0) + K_k [H \alpha(k, t_0) + \Xi \Upsilon_y(k, t_0)]$$

$$\beta(k, t_0) = F \beta(k - 1, t_0) + K_k \rho(k, t_0)$$

$$\rho(k, t_0) = H [\alpha(k, t_0) - F \beta(k - 1, t_0)] + \Xi \Upsilon_y(k, t_0)$$

con las condiciones iniciales:

$$\alpha(t_0, t_0) = 0$$

$$\beta(t_0 - 1, t_0) = 0$$

Notar que la marca del cambio de innovación $\rho(k, t_0)$ depende tanto de k y t_0 durante el comportamiento transitorio del filtro de Kalman. Cuando el estado estable es alcanzado, la marca depende solamente de la diferencia de k y t_0 , es decir $k - t_0$.

La forma cerrada de las expresiones α , β y ρ asumiendo el comportamiento estado estable del filtro de Kalman y usando el dominio del tiempo y representaciones de funciones de transferencia, se obtiene:

$$\rho(k, t_0) = \sum_{i=0}^{k-t_0-1} H \bar{F}^i \Gamma \Upsilon_x(k-i-1, t_0) - \sum_{i=0}^{k-t_0-1} H \bar{F}^i F \Gamma K \Xi \Upsilon_y(k-i-1, t_0) + \Xi \Upsilon_y(k, t_0) \quad (3.33)$$

En resumen, la innovación ε_k (salida del filtro de Kalman) tiene la siguiente distribución:[5]

$$\mathcal{L}(\varepsilon_k) = \mathcal{N}(0, \Sigma_k) \quad \text{cuando no ocurre cambio} \quad (3.34)$$

$$\mathcal{L}(\varepsilon_k) = \mathcal{N}(\rho(k, t_0), \Sigma_k) \quad \text{luego del cambio}$$

3.2.2. Innovación y Redundancia

3.2.2.1. Innovación

El concepto de innovación en procesos aleatorios, es el residuo de la proyección asociada con la estimación condicional dadas las observaciones pasadas. La importancia del concepto de la innovación en la detección de cambios aditivos es debido al efecto generado por los cambios aditivos en la innovación, o de forma mas precisa en el residuo, en el cual también se generan cambios en su valor medio.

En otras palabras, los cambios aditivos mantienen su efecto aditivo en virtud de la transformación de las observaciones a las innovaciones. [5]

3.2.2.2. La redundancia

El concepto de redundancia es ampliamente utilizado en aplicaciones de teoría de control y se relaciona básicamente con la disponibilidad de varias medidas verdaderas o artificiales de las mismas cantidades físicas.

La redundancia directa cobra importancia cuando varios sensores miden las mismas cantidades. Mientras, que la redundancia analítica refiere al uso de ambas medidas tanto físicamente disponibles como de medidas procesadas. Las medidas artificiales procesadas se construyen con la ayuda de relaciones dinámicas disponibles. Siendo las relaciones de redundancia o también llamadas vectores de paridad, las cuales son combinaciones lineales de valores de salidas actuales o presentes y valores pasados de entradas y salidas. Pueden ser obtenidas a través de proyecciones sobre el complemento ortogonal de la gama de la observación o de la matriz de la observabilidad. [5]

3.3. Diseño del Sistema de Detección de Fallas

El diseño del sistema de detección de fallas, tiene como objetivo la correcta detección de una falla a la vez, a pesar de los ruidos al sistema generados por ruido blanco gaussiano del proceso, así como también el ruido de la lectura del sensor.

Para el diseño del sistema, se determina su modelo, basándonos en el rango lineal del sistema, para poder determinar su función de transferencia como función de la entrada y salida del sistema, basándonos en su respuesta transitoria. Es debido, a que el sistema a identificar físicamente contempla al actuador, el motor de corriente continua y el sensor de velocidad, que es considerado un modelo total y no puede disgregarse en sistemas elementales reales básicos tales como los antes mencionados.

Consideraciones de Diseño

En el diseño del sistema de detección de fallas se han considerado la presencia de una sola falla presente en el sistema debido a que el sistema sólo contempla una salida con valores accesibles a ser leídos. En cambio, si el sistema presentara salidas accesibles a la lectura, se podría analizar la precedencia de la falla, haciendo uso de otros elementos como un banco de filtros de Kalman para cada salida del sistema, debido a que cada filtro de Kalman es diseñado para determinar la existencia de una falla presente en cada una de las diferentes salidas del sistema. [27]

Así mismo, se ha considerado la existencia de ruido blanco gaussiano en el proceso y en la lectura del sensor, basándose en el teorema del límite central para poder demostrar la presencia de los ruidos gaussianos.

Teorema del Límite Central *Se considera un grupo de variables aleatorias $x_1(t)$, $x_2(t)$. . . $x_n(t)$. Se asume independencia entre ellas, idénticamente distribuidos con media μ_x y desviación estandar σ_x .*

Definiendo una nueva variable como $z_n = x_1(t) + x_2(t) + \dots + x_n(t)$. La forma básica del teorema de límite central formula que:

$$\lim_{n \rightarrow \infty} P \left(\frac{Z_n - n\mu_x}{\sigma_x \sqrt{n}} \right) < \beta = \frac{1}{\sqrt{2\pi}} \int_{\xi}^{\beta} \exp \left[-\frac{\xi^2}{2} \right] d\xi$$

Esto es la distribución del promedio de Z_n/n , normalizada con su media μ_x y la desviación estándar σ_x/\sqrt{n} se aproxima a una distribución normal estándar $N(0,1)$ cuando $n \rightarrow \infty$. Nótese que, no se ha asumido sobre la distribución de la variable x , sólo su independencia mutua y la existencia de su media y desviación estándar.[27]

En la figura 3.4, se muestra el esquema general de detección y diagnóstico de fallas, en el cual la señal de falla $f_{(k)}$ actúa sobre el sistema determinando diferentes modos de operación (modo de operación normal y modo de operación con falla). Siendo las 2 etapas presentes para la determinación de la falla son: una etapa de generación de los residuos y una etapa posterior de evaluación de residuos.

El bloque de generación de residuos realiza el cálculo del vector de residuos $r_{(k)}$ mientras tanto el bloque de evaluación de residuos determina las fallas presentes en el sistema, de acuerdo a la información obtenida anteriormente acerca de las posibles fallas, procesando el vector de residuos. El resultado de la evaluación se representa mediante una señal de diagnóstico $d_{(k)}$ la cual es una estimación del vector $f_{(k)}$.

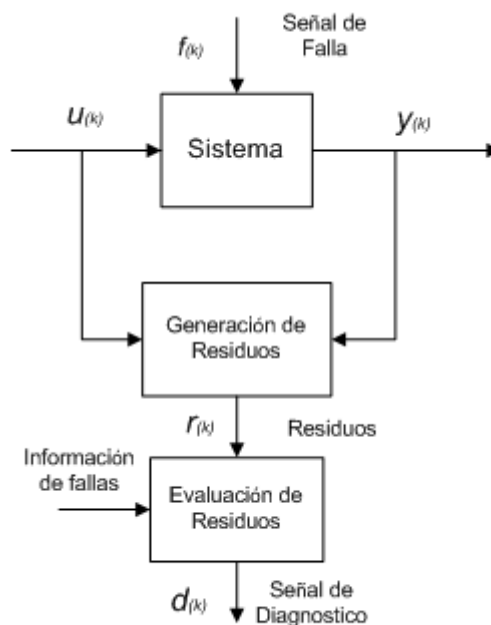


Figura 3.4: Esquema general de detección y diagnóstico de fallas

Generación de residuos

La generación de residuos tiene como base la comparación de las salidas entre 2 modelos diferentes con una misma entrada, un modelo sin fallas o modo de operación normal y otro con fallas o modo de operación con fallas, ambos basados en el modelamiento matemático del comportamiento del sistema. Mediante la comparación de ambos modelos en el tiempo se generan diferencias en la salida entre el modelo con fallas y el modelo sin fallas. Estas diferencias en el tiempo serán los patrones que se procesarán para la determinación de la existencia de la falla.

Evaluación de Residuos

La identificación de la fallas tiene como objetivo el análisis o procesamiento de las diferencias o residuos generados por la etapa de generación de residuos para la correcta determinación de la existencia de la falla basándose en información obtenida previamente sobre las características que determinan la presencia de la falla.

3.3.1. Generación de Residuos

Para la generación de los residuos se hará uso de 2 modelos, uno con fallas aditivas y otro sin fallas, ambos afectados por ruidos blancos gaussianos en el proceso y en la lectura. Mediante la revisión del comportamiento actual del sistema frente al modelo esperado o normal del sistema se buscará que ambos modelos sean consistentes, en caso de no ser consistentes, esa inconsistencia es expresada como un residuo a analizar.

En un esquema de FDI, los residuos corresponden a variables de análisis encargadas de representar información crucial para la detección y el diagnóstico. Entre las propiedades deseables para una variable residuo son las siguientes:

- Tener valores cercanos a cero para modos de operación normal, es decir modos donde no ocurre una falla.
- Que algún residuo alcance valores diferentes a cero para los modos de operación con fallas.
- Ser poco sensibles a errores de modelación.
- Ser muy sensibles a fallas
- Responder rápidamente a fallas.

Estocásticamente, un residuo se puede caracterizar como una variable aleatoria que en modo de operación normal posee media cero y que en un modo de operación con falla posee media diferente de cero.

En el modelo a analizar, se le agregarán fallas aditivas, estas fallas harán variar el comportamiento normal del sistema, al cual se le aplicará el filtro de Kalman discreto, mediante el cual se estimarán de manera óptima las variables internas del sistema y su

respectiva salida del sistema en función de las variables internas del sistema, aún cuando estas sean afectadas por ruido blanco gaussiano tanto en el proceso como en la lectura. Generándose una variable interna en el filtro de Kalman, denominada innovación, que determinará la existencia de fallas en el sistema.

3.3.1.1. Aplicación del filtro de Kalman discreto

Para la aplicación del filtro de Kalman, debemos modificar el modelo obtenido de su función de transferencia a un modelo de estado espacio.

El criterio de selección de la función de transferencia que representa al sistema es determinado por el índice de adecuación obtenido experimentalmente mediante la herramienta de identificación de sistemas, obteniéndose el máximo índice de adecuación para la siguiente función de transferencia:

$$G(s) = \frac{10,77(0,35923s + 1)}{(0,55021s + 1)(0,31005s + 1)} \exp(-0,15681s) \quad (3.35)$$

Haciendo uso del código presentado en el algoritmo 3.1, se convierte a la función de transferencia del motor DC del sistema continuo en un sistema discreto en espacio estado con un tiempo de muestreo de 0.1 segundos. Generándose las siguientes matrices en estado espacio:

$$F = \begin{bmatrix} 0,0415 & -0,3998 & -0,0986 \\ 0,3230 & 0,7856 & -0,0545 \\ 0,0893 & 0,3672 & 0,9916 \end{bmatrix}$$

$$G = \begin{bmatrix} 0,3230 \\ 0,1786 \\ 0,0276 \end{bmatrix}$$

$$H = \begin{bmatrix} -2,8349 & 3,7384 & 3,2882 \end{bmatrix}$$

$$J = \begin{bmatrix} 0 \end{bmatrix}$$

Posteriormente a la identificación de las matrices para el sistema discreto que definen el comportamiento del sistema, estas mismas matrices serán utilizadas como parámetros en el filtro de Kalman para su elaboración y utilización, logrando poder estimar el comportamiento del sistema frente a los ruidos blancos gaussianos de proceso y de lectura.

Modelamiento del Filtro de Kalman para el motor de corriente continua

El modelamiento presentado del filtro de Kalman, es para un sistema general SISO en donde intervienen las 4 matrices que definen el comportamiento del sistema. En la figura 3.5, se representa el proceso matemático recursivo que realiza el filtro de Kalman para poder realizar la estimación óptima del estado del proceso, mediante la minimización de la covarianza de la innovación o residuo haciendo uso de la ganancia de Kalman.

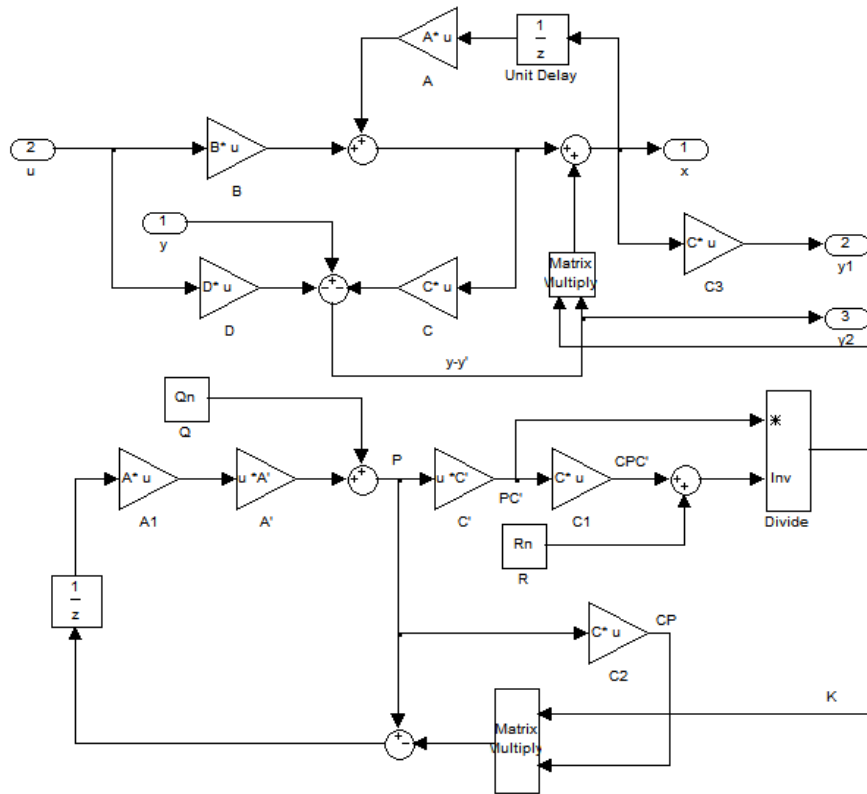


Figura 3.5: Representación gráfica del modelamiento del filtro de Kalman

Mediante este modelamiento recursivo y discreto del filtro de Kalman, se estimará la dinámica del comportamiento del sistema del motor de corriente continua, variando según los valores de las covarianzas de los ruidos blancos gaussianos, tanto del proceso Q, como de lectura R.

3.3.2. Evaluación del Residuo

El residuo generado mediante la comparación o incongruencia de los sistemas con falla y sin falla, es analizado o procesado para poder determinar con certeza la presencia de la falla en el sistema, basándose en características obtenidas previamente sobre el comportamiento de las fallas.

Para una determinación de la presencia de falla, se analizará la innovación proveniente

del filtro de Kalman ε_k en el estacionario del sistema. Donde la innovación en el filtro de Kalman en el sistema se define mediante las ecuaciones 3.36 , 3.37 y 3.38.[5]

$$\hat{X}_{k+1|k} = F\hat{X}_{k|k} + GU_k \quad (3.36)$$

$$\hat{X}_{k|k} = \hat{X}_{k|k-1} + K_k\varepsilon_k \quad (3.37)$$

$$\varepsilon_k = Y_k - H\hat{X}_{k|k-1} - JU_k \quad (3.38)$$

Los parámetros estadísticos a analizar de la innovación ε_k serán la media y la desviación estándar, dichos parámetros serán utilizados para poder determinar con certeza la presencia de la falla, ante cambios generados por ruido gaussiano blanco tanto para lectura , como del proceso.

Definiendo la salida de la innovación como un desviación normal mediante las ecuaciones 3.39, tanto para el proceso sin fallas así como el proceso donde existe presencia de falla.[5]

$$\mathcal{L}(\varepsilon_k) = \mathcal{N}(0, \Sigma_k) \quad \text{cuando no ocurre cambio} \quad (3.39)$$

$$\mathcal{L}(\varepsilon_k) = \mathcal{N}(\rho(k, t_0), \Sigma_k) \quad \text{luego del cambio}$$

Esta definición es valida cuando el filtro de Kalman ha llegado a su estado estable o constante, donde la covarianza del error $P_{k|k-1}$ converge a un estado estable P, y se comprueban las ecuaciones 3.40:

$$\lim_{k \rightarrow \infty} P_{k|k-1} = P_s \quad (3.40)$$

$$\lim_{k \rightarrow \infty} K_k = K_s$$

$$\lim_{k \rightarrow \infty} \bar{F}_k = \bar{F}_s$$

Mediante el análisis de la media de la innovación, se determina un residuo el cual cumple con las características deseables de ser cero o cercano a este valor para procesos donde no se encuentra la falla y tener un valor diferente de cero en el proceso donde se encuentra la falla, siendo la expresión $\rho(k, t_0)$ la cual se definió previamente mediante las ecuaciones 3.33.[5]

3.3.2.1. Diagnóstico por Ratio de Verosimilitud Generalizado

El diagnóstico de residuos en la detección de fallas usualmente envuelve el diagnóstico basándose en 2 hipótesis, la primera donde el residuo presenta una media igual a 0,

representando el caso donde no existe falla, mientras que la segunda hipótesis, donde la media es distinta a 0 y es representada como la presencia de falla.[30, 5]

$$H^1 : \mu_r = 0 \text{ no falla}$$

$$H^0 : \mu_r = 1 \text{ falla}$$

Este método de diagnóstico depende de la magnitud de la media del residuo y es afectado también por la distribución del ruido inducido al sistema y las entradas. El diagnóstico se diseñará mediante el ratio de la función logarítmica de verosimilitud (*log-likelihood ratio*), el cual permite generar una función, a partir de la innovación proveniente del filtro de Kalman para poder realizar una decisión entre ambas hipótesis H^1 y H^0 [27][30, 5]

El diagnóstico está basado en la función de densidad gaussiana de probabilidad, obtenida de la observación de los residuos obtenidos del parámetro innovación, siendo su función:

$$p(\mu, \sigma_r) = \frac{1}{\sqrt{2\pi}\sigma_r} \exp \left[-\frac{(y - \mu)^T (y - \mu)}{2\sigma_r^2} \right]$$

donde μ es la media de y , y σ_r^2 es la varianza de los residuos $y - \mu$. [30, 5]

Función Logarítmica de Verosimilitud

La función de verosimilitud de una sola observación y de una variable aleatoria es igual a su densidad de probabilidad, por lo que la función logarítmica de verosimilitud es el logaritmo natural de la función de verosimilitud:

$$l_\theta(y) = \ln p_\theta y$$

Donde la secuencia de observaciones y_k es agrupada en el vector Y_1^N , siendo su función logarítmica de verosimilitud [30, 5]

$$l_\theta(Y_1^N) = \ln \prod_{i=1}^N p_\theta(y_i | Y_1^{i-1})$$

$$l_\theta(Y_1^N) = \sum_{i=1}^N \ln p_\theta(y_i | Y_1^{i-1})$$

donde $p_\theta(y_1 | Y_1^0) \triangleq p_\theta(y_1)$.

Si las observaciones son independientes, la función se puede denotar como:

$$l_{\theta} \left(Y_1^N \right) = \sum_{i=1}^N \ln p_{\theta} (y_i)$$

Ratio de Función Logarítmica de Verosimilitud (LLR)

El ratio de función logarítmica de verosimilitud es una importante medida en la teoría de detección estadística, es usado para hacer una decisión entre 2 hipótesis, H^1 y H^0 acerca de la distribución de y caracterizado por θ . [30, 5]

$$H^0 : p_{\theta} = p_{\theta_0}$$

$$H^1 : p_{\theta} = p_{\theta_1}$$

El ratio logarítmico de verosimilitud $s(y)$ esta denotado por:

$$s(y) = \ln \frac{p_{\theta_1}(y)}{p_{\theta_0}(y)} = l_{\theta_1}(y) - l_{\theta_0}(y)$$

Siendo la medida de $s(y)$ positiva cuando H^1 es mas parecido a H^0 .

Para un conjunto de observaciones Y_1^N el LLR esta dado por:

$$s \left(Y_1^N \right) = l_{\theta_1} \left(Y_1^N \right) - l_{\theta_0} \left(Y_1^N \right)$$

Por consiguiente, el LLR de una observación y de un vector aleatorio con distribución gaussiana con una matriz de covarianza Σ , con una media de 0 para la hipótesis H^0 y con una media μ para la hipótesis H^1 está dado por: [30, 5]

$$s(y) = \mu^T \Sigma^{-1} y - \frac{1}{2} \mu^T \Sigma^{-1} \mu$$

donde se ha utilizado la simetria de la matriz de covarianza $\Sigma = \Sigma^T \Leftrightarrow \Sigma^{-1} = (\Sigma^{-1})^T$

Detección de saltos desconocidos en una variable aleatoria con distribución gaussiana

Considerando una variable aleatoria con distribución gaussiana y , con una matriz de covarianza constante Σ , pero con una media variable μ . Antes de tiempo de cambio t_0 la media es igual a μ_0 y desde el tiempo t_0 la media toma el valor de μ_1 . Suponiendo que μ_0 es un valor conocido, entonces el tiempo de cambio t_0 y el tamaño del salto $\nu = \mu_1 - \mu_0$ son desconocidos. [30, 5]

Dadas las observaciones Y_1^N se consideran 2 hipótesis:

$$(no\ cambio) H_0 : \mu = \mu_0$$

(cambio) $H_1 : \mu = \mu_0$ para $k < t_0$ y $\mu = \mu_1$ para $k \geq t_0$

Usando el LLR de las variables observadas almacenadas Y_1^N esta dado por:[30, 5]

$$s(Y_1^N) = \sum_{k=t_0}^N y_k^T \Sigma^{-1} (\mu_1 - \mu_0) - \frac{1}{2} (\mu_1 + \mu_0)^T \Sigma^{-1} (\mu_1 - \mu_0)$$

$$\hat{s}(Y_1^N) = (N - t_0 + 1) \left(\hat{\mu}_1^T \Sigma^{-1} - \frac{1}{2} (2\mu_0 + \nu)^T \Sigma^{-1} \nu \right)$$

Siendo $\hat{\mu}_1 = \frac{1}{N-t_0+1} \sum_{k=t_0}^N y_k$, la media de y desde el tiempo $k = t_0$ hasta $k = N$, se considera como la estimación de μ_1 .

La máxima estimación de verosimilitud del salto ν es deducido mediante la derivación de la ecuación e igualandola a 0.

$$\hat{\nu}(t_0) = \frac{1}{N - t_0 + 1} \sum_{k=t_0}^N y_k - \mu_0 = \hat{\mu}_1 - \mu_0$$

El ratio de función logarítmica de verosimilitud es calculado maximizándose con respecto a t_0 . [30, 5]

$$\hat{s}(Y_1^N) = \sum_{k=t_0}^N y_k^T \Sigma^{-1} \hat{\nu}(t_0) - \frac{1}{2} (2\mu_0 + \hat{\nu}(t_0))^T \Sigma^{-1} \hat{\nu}(t_0)$$

3.3.2.2. Implementación del Sistema de evaluación de la Innovación

3.3.3. Simulación de Filtro de Kalman para la detección de Fallas

En la figura 3.6, se muestra el diagrama general desarrollado para la detección de fallas aditivas presentes en un sistema SISO de un motor de corriente continua, haciendo uso de la herramienta de simulación Simulink de Matlab. Se ha discretizado el sistema con un tiempo de muestreo de 0.1 segundos. Mediante este diagrama, se visualiza salida de cada uno sistemas estudiados, motor sin fallas, motor con falla escalón y con falla rampa. Asi mismo, permite la realización del proceso de estimación mediante el filtro de Kalman, y su variable denominada “innovación” mediante la cual se genera un análisis estático de sus parámetros a fin de ser utilizados para la correcta identificación de la falla.

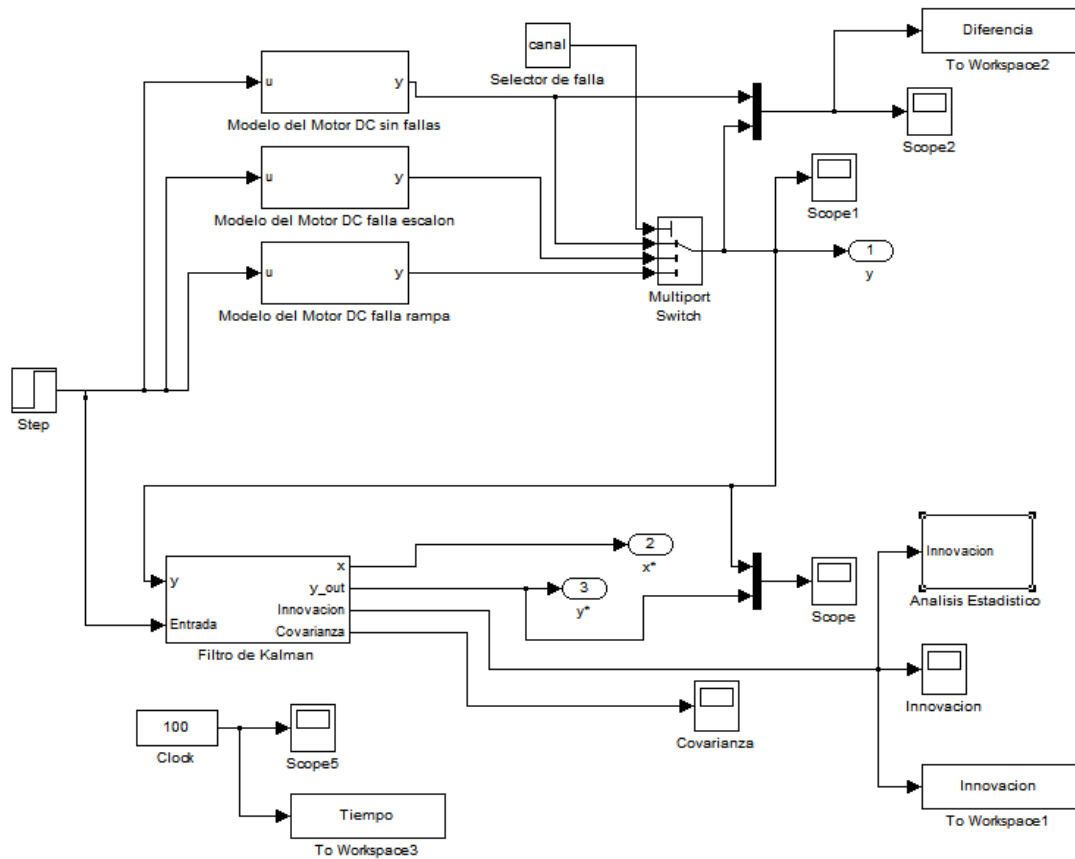


Figura 3.6: Herramienta de Simulación General para la detección de fallas

Para poder hacer uso del detector de fallas, es necesario hacer uso del algoritmo 3.1, el cual permite inicializar las condiciones iniciales del filtro de Kalman, así mismo las matrices que definen el comportamiento dinámico del proceso, las cuales son utilizadas como parámetros del diseño del filtro de Kalman para estimar correctamente el proceso .

Algorithm 3.1 Inicialización del Sistema de Detección de Fallas

```

% Tiempo de muestreo de señal discreta
Ts = 100e-3;
%Función de transferencia del retardo del sistema
[num_d,den_d] = pade(0.15,1);
%Función de transferencia del sistema continuo
num=[3.8689071 10.77]; den=[0.1705926 0.86926 1];
%Generación de la función de transferencia del sistema con retardo
num_sys=conv(num_d,num); den_sys=conv(den_d,den);
Gm=tf(num_sys,den_sys);
State= ss(Gm);
%% Diseño discreto
% Transformación del sistema continuo a discreto
dsys = c2d(State, Ts,'zoh');
%% Disgregación de las matrices en estado espacio
A = dsys.a;
B = dsys.b;
C = dsys.c;
D = dsys.d;
%Parámetros del ruido gaussiano del proceso y del sensor
Q1 = 0.16;% Varianza del ruido de proceso
R1 = 16;% Varianza del ruido del sensor
Q=Q1; R=R1;
Qm=sqrt(Q);
Rm=sqrt(R);
% Estado inicial
x0 = zeros(3,1);
x1 = zeros(3,1);
% Parámetros de Filtro de Kalman siendo los mismos parámetros del modelo del motor
% Covarianza inicial del estado X
P1 = 0.5*eye(3);
P0 = 0.5*eye(3);
%Parámetros de la falla
step_v=100;
falla=0.010*step_v*10.77;% representa al 0.1 de magnitud de falla en condiciones normales
fault_time=75;% tiempo de la falla
% Selector de tipo de fallas a analizar:
% canal 1 = SIN FALLA
% canal 2 = FALLA TIPO ESCALÓN
% canal 3 = FALLA TIPO RAMPA
canal=1;

```

El sistema general de detección mostrado, es representado mediante subsistemas para un mayor entendimiento y claridad de las acciones de detección de fallas. Mediante este sistema de simulación, se puede simular 3 tipos diferentes de fallas aditivas seleccionando adecuadamente la variable denominada canal.

Existen un conjunto de esquemas de fallas a analizar, las cuales pueden ser seleccionadas eligiendo el canal adecuado de análisis, el cual se define en la inicialización del sistema

- canal 1, proceso sin fallas
- canal 2, proceso con falla aditiva tipo escalón
- canal 3, proceso con falla aditiva tipo rampa

Se muestran a continuación los subsistemas creados

El esquema del sistema sin fallas, es representado mediante la figura 3.7, el cual representa un modelo idealizado del motor de corriente continua, en el cual existe ruido blanco gaussiano sin presencia de falla alguna.

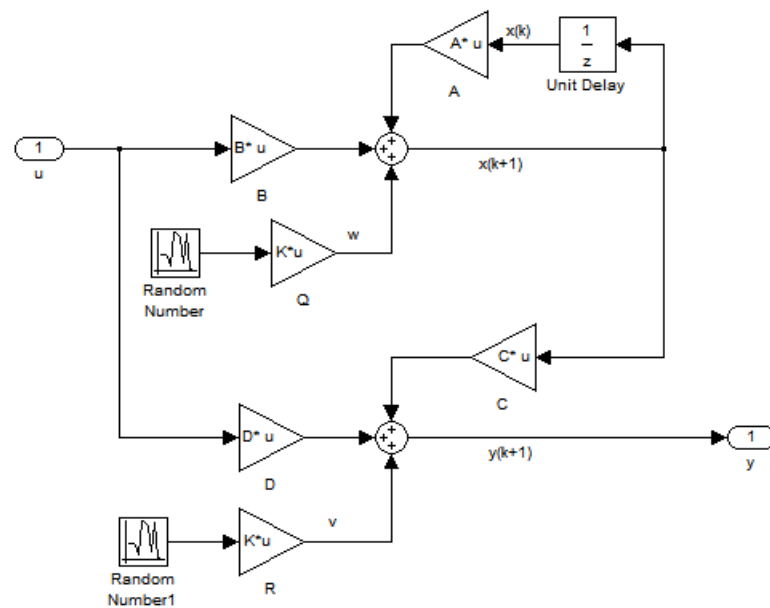


Figura 3.7: Modelo del Sistema sin Fallas

El primer esquema del sistema con fallas es representado mediante la figura 3.8, donde la falla aditiva tipo escalón es representada mediante la señal tipo escalón. Mientras que el ruido gaussiano blanco es agregado al sistema como un factor aditivo presente en el sistema y es representado mediante la multiplicación del bloque denominado *random number* con un factor multiplicativo según la magnitud del ruido presente.

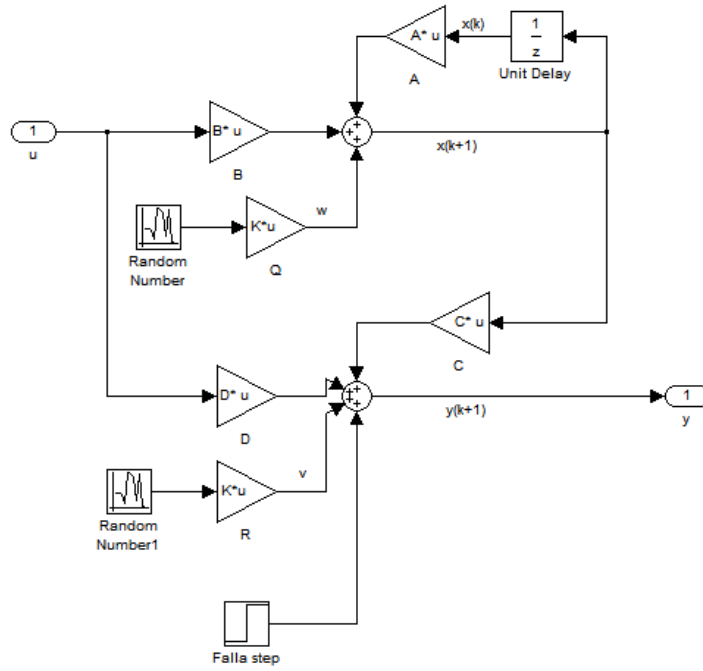


Figura 3.8: Modelo del sistema con fallas tipo escalón

El segundo esquema del sistema con fallas es representado mediante la figura 3.9, donde la falla aditiva tipo rampa es representada mediante la señal tipo rampa. Siendo también este modelo afectado por ruido gaussiano blanco tanto en el proceso, como en la lectura.

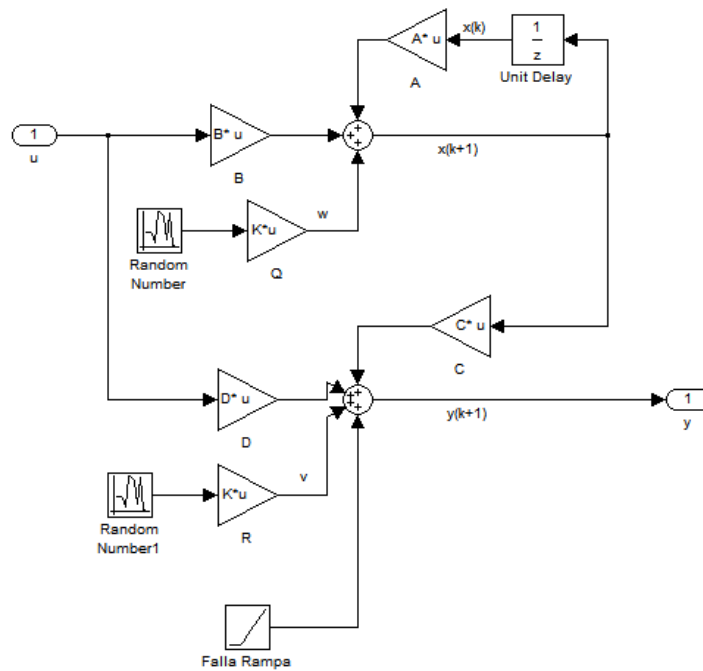


Figura 3.9: Modelo del sistema con fallas tipo rampa

El subsistema para el cálculo estadístico de los residuos generados del sistema en el transcurso del proceso de detección de falla, se representa mediante la figura 3.10. Siendo, el subsistema para el análisis estadístico de la innovación procedente del filtro de Kalman, el mismo utilizado para el cálculo estadístico de los residuos, mediante el cual se supervisan patrones estadísticos tales como media y desviación de la innovación procedente del filtro de Kalman.

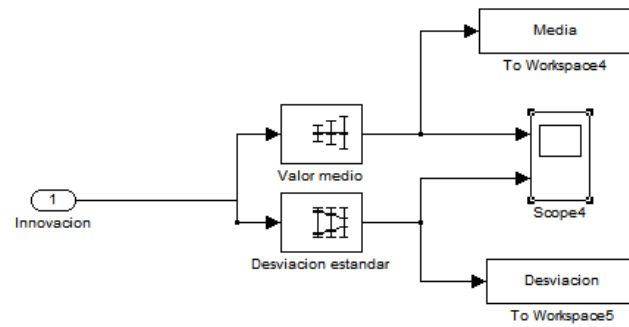


Figura 3.10: Subsistema para el cálculo estadístico del proceso

Para la correcta detección de la falla fuera de línea (*off-line*) se hace uso del algoritmo 3.2 de ratio logarítmico de verosimilitud implementado en código matlab, previamente se ha generado los datos necesarios mediante la simulación del motor DC ante las fallas aditivas.

Algorithm 3.2 Implementación de FDI fuera de línea

```

%Inicializacion
S_est=[];
t_est=[];
v_est=[];
u0=0;%media de la innovacion antes de falla
for i=30/Ts:100/Ts
sli=[];
for j=30/Ts:i
vj=1/(i-j+1)*sum(Innovacion.signals.values(j:i))-Media.signals.values(j);
sji=0;
for k=j:i
sji=sji+vj/Desviacion.signals.values(k)^2*(Innovacion.signals.values(k)-
Media.signals.values(k)-vj/2);
end;
sli=[sli;sji];
end;
% Determinacion de los valores de máxima verosimilitud
[s_max,t0_e]=max(sli);
v_e=1/(i-t0_e+1)*sum(Innovacion.signals.values(t0_e:i))-u0;
S_est=[S_est;s_max];
t_est=[t_est;t0_e];
v_est=[v_est;v_e];
end;
% Convirtiendo en una estructura con tiempo
S_est1.signals.values=double(S_est);
S_est1.time=double(Tiempo(300:1000));
figure;plot(S_est1.time,S_est1.signals.values);
%Convirtiendo en una estructura
t_est1.signals.values=double(30+t_est/10);
t_est1.samples=double(Tiempo(300:1000)*10);
figure;plot(t_est1.samples,t_est1.signals.values);
figure;plot(Diferencia.time,Diferencia.signals.values);
figure;plot(Media.time,Media.signals.values);
figure;plot(Desviacion.time,Desviacion.signals.values);
figure;plot(Innovacion.time,Innovacion.signals.values);

```

Capítulo 4

Pruebas y Análisis de Resultados

4.1. Introducción

Para el análisis de la efectividad de la generación de la innovación en la detección de fallas haciendo uso del algoritmo del Filtro de Kalman aplicado al motor de corriente continua, se ha tomado como base la comparación entre los resultados obtenidos al realizar un sistema de detección de fallas mediante el uso del ratio generalizado de verosimilitud (GLR) aplicado a los cambios aditivos en sistemas lineales, como el motor DC estudiado.

Se analizarán 2 tipos de fallas aditivas teóricas para la verificación de la efectividad del algoritmo de Kalman. Las fallas aditivas son tipo escalones y tipo rampas.

4.2. Resultados y Análisis de la Innovación

Mediante simulación se generaron diferentes comparaciones del modelo del sistema con falla y sin falla, con su respectivo filtro de Kalman para estimar las variables del sistema ante presencia de ruido blanco gaussiano.

Para el análisis del sistema de diagnóstico de presencia de fallas, se ha considerado tomar desde los 30 segundos debido a que es el tiempo en que se demora el filtro de Kalman en estabilizarse y el sistema se encuentra en estado estable. Generando los siguientes resultados:

4.2.1. Modelamiento sin Falla

Se generó los resultados siguientes en un sistema sin presencia de fallas para poder tomar como referencia.

4.2.1.1. Innovación del Filtro de Kalman

En la figura 4.1, se muestra el parámetro innovación proveniente del filtro de Kalman el cual es afectado por ruido gaussiano.

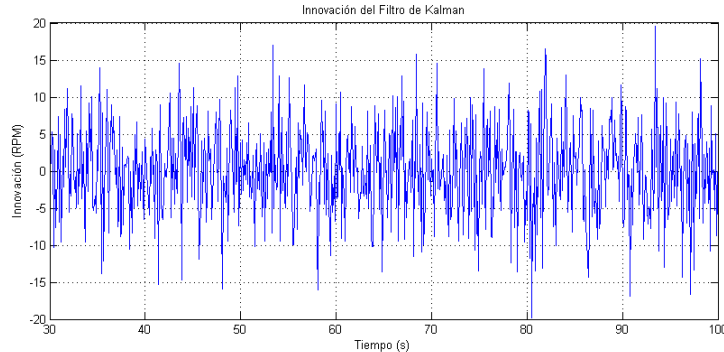


Figura 4.1: Innovación proveniente del Filtro Kalman sin presencia de falla

4.2.1.2. Media de la Innovación

En la figura 4.2, se muestra la media de la innovación proveniente del filtro de Kalman para un modelamiento sin presencia de falla de los 30s hasta los 100s. Se comprueba que la media del parámetro innovación es en promedio 0 ó con tendencia a 0.

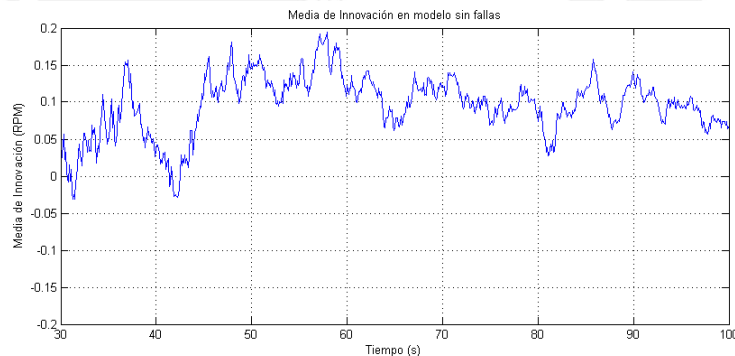


Figura 4.2: Media de la Innovación proveniente del Filtro Kalman sin presencia de falla

4.2.1.3. Desviación de la Innovación

En la figura 4.3, se muestra la desviación de la innovación proveniente del filtro de Kalman para un modelamiento sin presencia de falla de los 30s hasta los 100s. Se comprueba que la desviación del parámetro innovación se mantiene constante en el tiempo con un grado de error menor al 3%.




Figura 4.3: Desviación de la Innovación proveniente del Filtro Kalman sin presencia de falla

4.2.2. Modelamiento con Falla

Mediante simulación se generaron diferentes modelos de sistemas con fallas aditivas, haciendo uso del filtro de Kalman para estimar las variables del sistema ante presencia de ruido blanco gaussiano de lectura y proceso.

4.2.2.1. Modelamiento de Falla Aditiva tipo escalón

En este modelo se generó una falla aditiva tipo escalón de magnitud 10,7 RPM (1% de velocidad de trabajo normal) a los 75 segundos de iniciado el sistema. Generándose los siguientes resultados:

- Salida del modelo del motor DC

En la figura 4.4, se muestra el parámetro de salida del modelo del motor DC, específicamente la velocidad del motor DC. Donde se aprecia la falla aditiva tipo escalón a los 75 segundos tomando como comparación la salida del sistema sin presencia de falla. Sin embargo este comportamiento del sistema ante una falla aditiva no sería identificable si no tomamos como comparación la salida del modelo sin presencia de falla. Es debido a ello, el uso del parámetro innovación que nos provee de los parámetros estadísticos necesarios para su correcta identificación de la falla.




Figura 4.4: Comparación en la salida para modelos sin falla y con falla escalón

- Innovación del Filtro de Kalman

En la figura 4.5, se muestra el parámetro innovación proveniente del filtro de Kalman el cual es afectado por el ruido gaussiano.

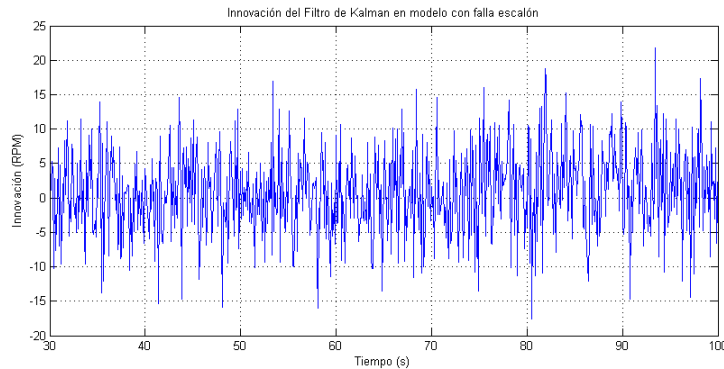


Figura 4.5: Innovación proveniente del Filtro Kalman en presencia de falla escalón

- Media de la Innovación

En la figura 4.6, se muestra la media de la innovación con la presencia de una falla tipo escalón a los 75 segundos de iniciado el sistema. Siendo esta falla no sólo perceptible visualmente, además es fácilmente identificable mediante el método estadístico propuesto.

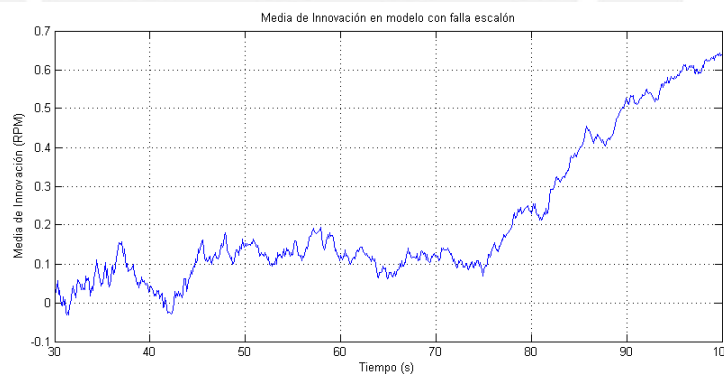


Figura 4.6: Media de la Innovación proveniente del Filtro Kalman en presencia de falla escalón

- Desviación de la Innovación

En la figura 4.7, se muestra la desviación de la innovación con la presencia de una falla a los 75 segundos de iniciado el sistema. Siendo la diferencia entre la desviación de la innovación en un modelo sin fallas y a la desviación para un proceso sin falla nula o casi nula, verificándose la teoría aplicada para fallas aditivas presentada.




Figura 4.7: Desviación de la Innovación proveniente del Filtro Kalman en presencia de falla escalón

4.2.2.2. Modelamiento de Falla Aditiva tipo rampa

En este modelo se generó un falla tipo aditiva tipo rampa cuya pendiente es 1 RPM/s y su punto de partida o referencia es a los 75 segundos de iniciado el sistema. Obteniéndose los siguientes resultados:

- Salida del modelo del motor DC

En la figura 4.8, se muestra el parámetro de salida del modelo del motor DC, específicamente la velocidad del motor DC. Donde se aprecia la falla aditiva tipo rampa a los 75 segundos tomando como comparación la salida del sistema sin presencia de falla. Sin embargo este comportamiento del sistema ante una falla aditiva no sería identificable si no tomamos como comparación la salida del modelo sin presencia de falla. Es debido a ello, el uso del parámetro innovación que nos provee de las variables estadísticas necesarias para su correcta identificación de la falla.




Figura 4.8: Comparación en la salida para modelos sin falla y con falla rampa

- Innovación del Filtro de Kalman

En la figura, 4.9, se muestra el parámetro innovación proveniente del filtro de Kalman el cual es afectado por el ruido gaussiano.

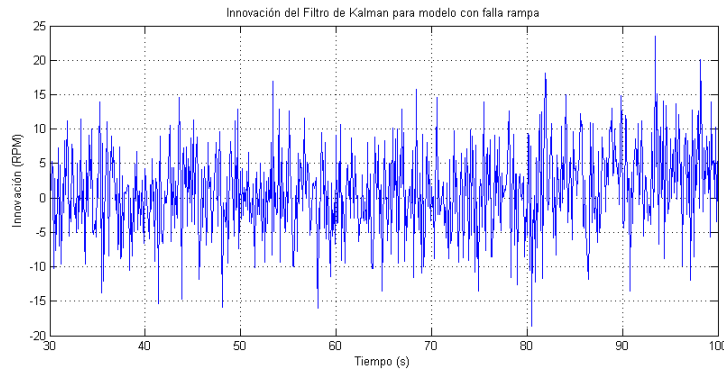


Figura 4.9: Innovación proveniente del Filtro Kalman en presencia de falla rampa

- Media de la Innovación

En la figura 4.10, se muestra la media de la innovación con la presencia de una falla tipo rampa a los 75 segundos de iniciado el sistema. Siendo esta falla no sólo perceptible visualmente, además es identificable mediante el método estadístico propuesto.




Figura 4.10: Media de la Innovación proveniente del Filtro Kalman en presencia de falla rampa

- Desviación de la Innovación

En la figura 4.11, se muestra la desviación de la innovación con la presencia de una falla a los 75 segundos de iniciado el sistema. Siendo la diferencia entre la desviación de la innovación en un modelo sin fallas y a la desviación para un proceso sin falla nula o casi nula, verificándose la teoría aplicada para fallas aditivas presentada.




Figura 4.11: Desviación de la Innovación proveniente del Filtro Kalman en presencia de falla rampa

4.2.3. Análisis de los Resultados

Analizando los resultados obtenidos para el modelamiento con falla y sin fallas, se aprecia que haciendo solo uso de la innovación del filtro de Kalman no es suficiente para la determinación de las fallas aditivas por lo que es necesario hacer uso de los parámetros media y desviación de la innovación.

Por ello, realizando una comparación de la media de la innovación para el modelo con falla y sin falla, se aprecia el cambio en el media para cada falla aditiva presentada, lo cual permite la determinación de la falla basándose en los cambios de la media de la innovación haciendo uso del sistema de diagnóstico de fallas.

Analizando posteriormente la desviación de la innovación se aprecia que el cambio en el tiempo es casi nulo para el modelo con y sin falla, esto confirma el criterio de diseño expuesto, mediante el cual ante una falla aditiva, la innovación proveniente del filtro de Kalman conserva los valores de la desviación en el tiempo, mientras que genera un cambio aditivo distinguible en la media de la innovación. Permitiendo así la determinación, tanto del tiempo de ocurrencia de la falla, así como la magnitud de la misma, siendo el análisis de la innovación el método más confiable del uso del filtro de Kalman para la determinación de la falla.

Es debido a la minimización de la presencia del ruido blanco gaussiano en el proceso de la innovación del filtro de Kalman y la disminución de la dependencia de la magnitud de la falla aditiva, que el análisis de la innovación generada por el filtro de Kalman es un método con mejores prestaciones para la correcta determinación de las fallas que hacer uso de la comparación de los residuos o diferencias existentes en las salidas de los sistemas con fallas aditivas y sin fallas.

4.3. Resultados y Análisis del GLR

Mediante el algoritmo de Ratio generalizado de verosimilitud (GLR) se generan las variables estadísticas suficientes para la correcta determinación de la falla, haciendo uso de los valores de innovación, media de la innovación y desviación de la innovación en el transcurso del tiempo.

Haciendo uso de los parámetros estadísticos de la innovación, se logra estimar la magnitud de los saltos en cada instante del tiempo de la innovación del sistema, siendo dichos saltos usados para el cálculo de la máxima verosimilitud determinando de manera confiable la presencia de falla en el sistema

Se presentan los resultados para los modelos sin presencia de falla, con falla aditiva tipo escalón y falla aditiva tipo rampa.

4.3.1. Modelamiento sin Falla

En las figuras 4.12 y 4.13, se presentan los resultados obtenidos al aplicar el método de detección de fallas fuera de línea haciendo uso del ratio generalizado de verosimilitud.




Figura 4.12: Ratio generalizado de verosimilitud en modelo sin fallas




Figura 4.13: Estimación del tiempo de falla en modelo sin fallas

4.3.2. Modelamiento con Falla

4.3.2.1. Modelamiento con Falla aditiva tipo escalón

En las figuras 4.14 y 4.15, se presentan los resultados obtenidos al aplicar el método de detección de fallas fuera de línea haciendo uso del ratio generalizado de verosimilitud para la detección de la falla escalón.




Figura 4.14: Ratio generalizado de verosimilitud en modelo con falla escalón




Figura 4.15: Estimación del tiempo de falla en modelo con falla escalón

En el cuadro 4.1, se muestran los resultados obtenidos con diferentes amplitudes de falla aditiva tipo escalón bajo un mismo tiempo de falla. Donde las variables mostradas representan:

Falla (%), incremento instantáneo de la falla en el sistema.

μ (t=75s), media de la innovación a los 75 segundos de iniciado el sistema, antes de la presencia de falla.

μ (t=100s), media de la innovación a los 100 segundos de iniciado el sistema, después de la presencia de falla.

GLR (t=75s), ratio de verosimilitud a los 75 segundos de iniciado el sistema, antes de la presencia de falla.

GLR (t=100s), ratio de verosimilitud a los 100 segundos de iniciado el sistema, después de la presencia de falla.

Falla (%)	μ (t=75s)	μ (t=100s)	GLR (t=75s)	GLR (t=100s)	Detección
0.1	0.0689	0.1216	2.0534	0.3461	NO
0.2	0.0689	0.1787	2.0534	0.7256	NO
0.3	0.0689	0.2359	2.0534	1.3060	NO
0.4	0.0689	0.2931	2.0534	2.0519	NO
0.5	0.0689	0.3502	2.0534	3.0913	NO
0.6	0.0689	0.4074	2.0534	4.4576	NO
0.7	0.0689	0.4645	2.0534	6.0679	NO
0.8	0.0689	0.5217	2.0534	7.9188	SI
0.9	0.0689	0.5780	2.0534	10.0069	SI
1	0.0689	0.6360	2.0534	12.3280	SI
2	0.0689	1.2076	2.0534	47.2167	SI

Cuadro 4.1: Resultados obtenidos para detección de fallas tipo escalón

4.3.2.2. Modelamiento con Falla aditiva tipo rampa

En la figura 4.16 y 4.15, se presentan los resultados obtenidos al aplicar el método de detección de fallas fuera de línea haciendo uso del ratio generalizado de verosimilitud para la detección de la falla rampa.




Figura 4.16: Ratio generalizado de verosimilitud en modelo con falla rampa




Figura 4.17: Estimación del tiempo de falla en modelo con falla rampa

En el cuadro 4.2, se muestran los resultados obtenidos con diferentes pendientes de falla aditiva rampa bajo un mismo tiempo de falla generándose diferentes incrementos totales para fallas aditivas tipo rampa. Donde las variables mostradas representan:

Falla (%), incremento total de la falla en el sistema.

μ ($t=75s$), media de la innovación a los 75 segundos de iniciado el sistema, antes de la presencia de falla.

μ ($t=100s$), media de la innovación a los 100 segundos de iniciado el sistema, después de la presencia de falla.

GLR ($t=75s$), ratio de verosimilitud a los 75 segundos de iniciado el sistema, antes de la presencia de falla.

GLR ($t=100s$), ratio de verosimilitud a los 100 segundos de iniciado el sistema, después de la presencia de falla.

Falla (%)	μ ($t=75s$)	μ ($t=100s$)	GLR ($t=75s$)	GLR ($t=100s$)	Detección
0.1	0.0689	0.0984	2.0534	0.3504	NO
0.2	0.0689	0.1224	2.0534	0.4604	NO
0.3	0.0689	0.1514	2.0534	0.7792	NO
0.4	0.0689	0.1803	2.0534	1.1806	NO
0.5	0.0689	0.2093	2.0534	1.6644	NO
0.6	0.0689	0.2383	2.0534	2.2304	NO
0.7	0.0689	0.2673	2.0534	2.8785	NO
0.8	0.0689	0.2963	2.0534	3.6082	NO
0.9	0.0689	0.3252	2.0534	4.4193	SI
1	0.0689	0.3542	2.0534	5.3113	SI
2	0.0689	0.6440	2.0534	18.5634	SI

Cuadro 4.2: Resultados obtenidos para detección de fallas tipo rampa

4.3.3. Análisis de los Resultados

En la figura 4.13, se aprecia la estimación del tiempo de falla para un sistema sin presencia de falla, considerándose como tiempo de falla aquel valor de tiempo que permanezca estable o constante ante el incremento de las muestras de innovación procesadas. Sin embargo, para la estimación del tiempo de falla en el sistema sin presencia de falla no tiende a un valor constante en el rango de muestras procesadas por el algoritmo, significando la no presencia de falla en el tiempo de procesamiento del algoritmo de detección de fallas fuera de línea.

Sin embargo, las figuras 4.15 y 4.17, se muestra como ante el aumento de muestras procesadas de innovación, las estimaciones del tiempo de falla aditiva escalón y rampa tienden a un valor constante, siendo dichos tiempos 75 segundos y 81.5 segundos respectivamente.

Esto evidencia que el sistema de detección fuera de línea ante fallas escalones puede detectar la falla aditiva con un mayor grado de rapidez que el sistema de detección ante fallas tipo rampa, debido a que la falla escalón es una falla instantánea que afecta al sistema como se evidencia en la figura 4.14, mientras que la falla tipo rampa es una falla que va aumentando su valor de manera progresiva. Por lo que a los 81.5 segundos el incremento sucesivo de la falla rampa afecta al sistema como se evidencia en la figura 4.16.

Analizando los resultados obtenidos para el modelamiento con falla tanto escalón y rampa resumidos en los cuadros 4.1 y 4.2, donde haciendo uso de los parámetros media y desviación de la innovación del filtro de Kalman se ha generado el ratio de verosimilitud,

el cual permite la correcta determinación de la presencia de falla aditiva en el sistema. Detectando correctamente, fallas aditivas tipo escalón, cuya amplitud de falla supere el 0.8 % del valor de la variable de salida del sistema y fallas aditivas tipo rampa, cuya incremento total supere el 0.9 % de la variable de salida del sistema.

De igual manera, se aprecia la relación directa existente entre el del ratio de verosimilitud y de la media de la innovación ante cambios de la amplitud de la falla.

Comprobando que el método de Ratio de Verosimilitud es una método confiable para la correcta determinación de las fallas aditivas presentadas, debido a que permite la determinación del tiempo de falla.



Conclusiones

Se diseñó un sistema de detección e identificación de fallas fuera de línea que permite una correcta determinación de fallas aditivas presentes en el sensor de velocidad de un motor de corriente continua con excitación independiente, empleando las propiedades estadísticas del parámetro “innovación” proveniente del filtro de Kalman para la creación del ratio generalizado de verosimilitud, el cual permite la correcta detección de la falla.

El sistema de detección de fallas desarrollado incluye un procedimiento de análisis de residuos denominado Ratio generalizado de verosimilitud basado en las estadísticas de la “innovación” provenientes del filtro de Kalman, que permite detectar satisfactoriamente fallas aditivas tales como: escalones y rampas.

Se desarrollaron tareas de identificación del motor de excitación independiente, llegando a la conclusión de que este dispositivo se representa como un sistema de segundo orden con un retardo de tiempo de 0.15 segundos, cuyo modelo fue discretizado y utilizado para el diseño de los parámetros utilizados en el filtro de Kalman.

Desarrollando once pruebas con diferentes magnitudes de fallas para cada una de las fallas aditivas propuestas, para el sistema diseñado se concluye que es capaz de detectar fallas aditivas tipo escalón superiores al 0.8% de la magnitud de la velocidad de trabajo del motor estudiado y fallas aditivas tipo rampa cuyo incremento total supera el 0.9% de la magnitud de la velocidad de trabajo del motor estudiado.

Recomendaciones

La cantidad y variedad de técnicas de detección e identificación de fallas son abundantes y aplicables bajo diferentes consideraciones de diseño y a diferentes modelos de sistemas. Por consiguiente es recomendable el análisis y la comparación en eficiencia de la metodología de detección presentada con otras metodologías aplicables para modelos de fallas aditivas.

El sistema presentado a analizar en un sistema SISO el cual contempla solo una entrada y una salida del sistema, sin embargo es recomendable analizar la factibilidad de la aplicación del filtro de Kalman para diferentes sistemas entre ellos SIMO, MISO y MIMO. Así mismo, analizar la viabilidad del uso del filtro de Kalman en sistemas variantes en el tiempo y en sistemas no lineales.

Se recomienda que toda planta industrial de gran envergadura posea uno o varios sistemas de detección e identificación de fallas, mediante los cuales se disminuya riesgos humanos, pérdidas materiales y disminuir tiempos de parada.

Una recomendación es revisar e investigar metodologías de detección e identificación de fallas aplicables a fallas de origen multiplicativo, las cuales afectan a la función de transferencia del sistema modificando sus parámetros internos y por consiguiente su respuesta a diferentes entradas.

Las perturbaciones como uno de los elementos presentes en un sistema real no ha sido considerado en el diseño del sistema de detección e identificación de fallas, por lo que se recomienda hacer su inclusión en el modelamiento del sistema convirtiéndose en un sistema mas próximo a la realidad.

Bibliografía

- [1] K. Y. S. N. K. Venkat Venkatasubramanian, Raghunathan Rengaswamy, “A review of process fault detection and diagnosis part i: Quantitative model-based methods,” *Computers and Chemical Engineering*, vol. 27, pp. pp 293–311, 2003.
- [2] R. Iserman, “Model-based fault detection and diagnosis status and applications,” *IFAC*, 2004.
- [3] M. I. Ribeiro, “Kalman and extended kalman filters: Concept, derivation and properties,” *Institute for Systems and Robotics*, 2004.
- [4] K. Y. S. N. K. Venkat Venkatasubramanian, Raghunathan Rengaswamy, “A review of process fault detection and diagnosis part ii: Qualitative models and search strategies,” *Computers and Chemical Engineering*, vol. 27, pp. pp 313 – 326, 2003.
- [5] I. V. Michele Basseville, *Detection of Abrupt Changes: Theory and Application*. Prentice-Hall, 1993.
- [6] P. Frank, “On-line fault detection in uncertain nonlinear systems using diagnostic observers: a survey,” *International Journal Systems Science*, vol. 25, pp. 2129–2154, 1994.
- [7] A. Willsky, “A survey of design methods for failure detection in dynamic systems,” *Automatica*, vol. 12, pp. 601–611, 1976.
- [8] R. Clark, “The dedicated observer approach to instrument fault detection,” *In Proceedings of the 15th IEEE-CDC*, pp. pp 237–241, 1979.
- [9] M. Massoumnia, “A geometric approach to the synthesis of failure detection filters,” *IEEE Transactions on Automatic Control AC*, vol. 31, pp. 839–846, 1986.
- [10] D. S. D. W. . K. D. Y. Dingli, J.B. Gomm, “Fault diagnosis for a gas-fired furnace using bilinear observer method,” in *In Proceedings of the American control conference*, 1995.
- [11] H. Y. . M. Saif, “Nonlinear adaptive observer design for fault detection,” in *In Proceedings of the American Control Conference*, pp. pp. 1136–1139, 1995.
- [12] V. Vaclavek, “Gross systematic errors or biases in the balance calculations,” *Prague Institute of technology*, 1984.

- [13] Y. Ben-Haim, “An algorithm for failure location in a complex network,” *Nuclear Science and Engineering*, vol. 75, pp. pp 191–199, 1980.
- [14] Y. Ben-Haim, “Malfunction location in linear stochastic systems-application to nuclear power plants,” *Nuclear Science and Engineering*, vol. 85, pp. pp 156 – 166, 1983.
- [15] . S. D. J.Gertler, “A new structural framework for parity equation-based failure detection and isolation,” *Automatica*, vol. 26, pp. pp 381 – 388, 1990.
- [16] K. A. E. O. Iri, M. and M. . H., “An algorithm for diagnosis of system failures in the chemical process,” *Computer & Chemical Engineering*, vol. 3 (1-4), pp. pp.489–493, 1979.
- [17] S.-L. J.-J. Hui Cheng, Mats Nikus, “Enhanced causal digraph reasoning for fault diagnosis with application on the paper machine short circulation process,” Master’s thesis, Helsinki University of Technology Laboratory of Process Control and Automation Kemistintie, 2003.
- [18] S. G. Leyval, L. and F.-b. S., “Model-based causal reasoning for process supervision,” *Automatica*, vol. 30, pp. pp. 1295–1306, 1994.
- [19] J. Montmain and G. S., “Dynamic causal model diagnostic reasoning for online technical process supervision,” *Automatica*, vol. 36, pp. pp. 1137–1152, 2000.
- [20] J. B. Fussell, “Fault tree analysis - state of the art,” *IEEE Transactions on Reliability*, vol. 23 (1), pp. 51 – 53, 1974.
- [21] . B.-S. de Kleer, J., “A qualitative physics based on confluences,” *Artificial Intelligence*, vol. 24 (1-3), pp. 7–83, 1984.
- [22] . K.-M. A. . . Finch, F. E., “Narrowing diagnostic focus using functional decomposition,” *American Institute of Chemical Engineers Journal*, vol. 34 (1), pp. pp 130 – 140, 1987.
- [23] S. J. Chapman, *Maquinas Electricas*. Mc Graw Hill, 3era edicion ed., 2000.
- [24] K. Ogata, *Modern Control Engineering*. Prentice-Hall, 1998.
- [25] Mathworks, “System identification toolbox user’s guide,” 2010.
- [26] I. BECHTEL GROUP, *Electric Motor Predictive and Preventive Maintenance Guide*. Nuclear Maintenance Applications Center, 2006.
- [27] J. J. Gertler, *Fault Detection and Diagnosis in Engineering Systems*. Marcel Dekker, 1998.
- [28] R.E.Kalman, “A new approach to linear filtering and prediction problems.,” *Journal of Basic Engineering*, p. 12, 1960.

- [29] G. Welch and G. Bishop, “An introduction to the kalman filter,” *Department of Computer Science*, 2006.
- [30] R. Fraanje, “Model-based fault detection and isolation,” 1999.
- [31] A. P. Andrews., *Kalman Filtering: Theory and Practice using MATLAB*. John Wiley & sons, third edition ed., 2008.
- [32] G. C. Charles K.Chui, *Kalman Filtering with Real-Time Applications*. Spring, fourth edition ed., 1987.
- [33] D. P. . S. Kroupa, “Reduced bank of kalman filters,” in *Proceedings of the 17th World Congress, IFAC*, pp. pp. 7245–7250, 2008.

