

**ESTUDIO COMPARATIVO DE MÉTODOS DE DETECCIÓN DE FALLOS EN SISTEMAS DE
EVENTOS DISCRETOS TEMPORIZADOS ESTOCÁSTICOS**



RUBÉN ESTEBAN SANTILLÁN MOSQUERA

Trabajo de grado. Maestría en Automática

Director:

Ph.D.: Mariela Muñoz Añasco

Universidad del Cauca

Facultad de Ingeniería Electrónica y Telecomunicaciones

Maestría en Automática

Popayán, noviembre 2023

RUBÉN ESTEBAN SANTILLÁN MOSQUERA

ESTUDIO COMPARATIVO DE MÉTODOS DETECCIÓN DE FALLOS EN SISTEMAS DE EVENTOS
DISCRETOS TEMPORIZADOS ESTOCÁSTICOS

Trabajo de grado presentado a la Facultad de Ingeniería

Electrónica y Telecomunicaciones de la

Universidad del Cauca para la obtención del

Título de

Magíster en Automática

Director:

Ph.D. Mariela Muñoz Añasco

Popayán

2023

Tabla de contenido

Resumen	1
Abstract	2
Lista de figuras	3
Lista de tablas	6
1 Introducción	7
2 Revisión de literatura	12
2.1 Marco Conceptual.....	12
2.2 Estado del arte	13
2.3 Modelado de sistemas de eventos discretos temporizados a partir de métodos de identificación	14
2.4 Detección y aislamiento de fallos temporales en DES.....	20
2.5 Eficiencia en la detección y el aislamiento temporizado en DES.	29
3 Diseño de Metodológico	30
3.1 Selección de los métodos de detección y aislamiento de fallos a comparar	30
3.2 Programación y validación de algoritmos.....	32
3.2.1 Algoritmo No. 1	32
3.2.2 Algoritmo No. 2	38
3.3 Diseño de la investigación	42

3.3.1	Variables del experimento	42
3.3.2	Proceso de experimentación	43
4	Presentación de resultados	46
4.1	Caso de estudio No. 1	46
4.2	Caso de estudio No. 2	51
4.3	Caso de estudio No. 3	59
5	Discusión de resultados	65
5.1	Fallos inducidos.....	65
5.1.1	Fallos inducidos y detectados por los algoritmos	65
5.1.2	Falsas alarmas.....	68
5.2	Sensibilidad y especificidad	70
5.2.1	Sensibilidad y especificidad comparada con intensidad de ruido	70
5.2.2	Sensibilidad.....	75
5.2.3	Especificidad	77
5.3	Tiempo de ejecución.....	80
6	Comparación de los algoritmos en un modelo identificado de un sistema estocástico con comportamiento no observable	82
7	Conclusiones.....	92
8	Bibliografía.....	94

9	Anexos	99
	Anexo 1. Datos generados del caso de estudio 1.....	99
	Anexo 2. Datos generados del caso de estudio.....	102
	Anexo 3. Datos generados del caso de estudio.....	105
	Anexo 4. Datos generados del modelo con comportamiento no observable	108

Resumen

En este documento se presenta la comparación del desempeño de dos algoritmos de detección de fallos en sistemas de eventos discretos temporizados estocásticos, por medio de una metodología propuesta como resultado de esta investigación. Esta metodología permite evaluar los métodos de detección y aislamiento de fallos en sistemas de eventos discretos. Las medidas que permiten esta evaluación de desempeño son cuatro: sensibilidad y especificidad para determinar la tasa de eventos de fallos y eventos libres de fallos clasificados correctamente, el análisis de la varianza, y por último el tiempo de ejecución que tarda cada algoritmo en realizar la detección. El desempeño se pone a prueba por medio de diferentes casos de estudios de diversas complejidades.

Además, el desempeño se evalúa en un sistema dinámico más complejo con aplicación industrial con la característica particular de contar con un número bajo de sensores. Este sistema es modelado con un método de identificación producto de esta investigación. El método de identificación genera un modelo con comportamiento no observable, este modelo se utiliza como un caso de estudio adicional para evaluar el desempeño de los algoritmos a comparar.

Abstract

This paper presents the comparison of the performance of two fault detection algorithms in stochastic timed discrete event systems, using a methodology proposed in this research. This methodology allows the evaluation of fault detection and isolation methods in discrete event systems. The performance evaluation is performed with four measures: sensitivity and specificity to determine the rate of correctly classified faulty events and fault-free events, analysis of variance, and finally the execution time taken by each algorithm to perform the detection. A test is performed with several case studies of varying complexity.

The performance is evaluated on a more complex dynamic system of industrial application with the particular characteristic of having a small number of sensors. This system is modeled with an identification method of this research. The identification method generates a model with unobservable behavior, this model is used as an additional case study to evaluate the performance of the algorithms to be compared.

Lista de figuras

Figura 1. Bases de datos consultadas.....	14
Figura 2. Proceso de identificación	15
Figura 3. Generador de eventos.....	16
Figura 4. Eventos reactivos. Adaptada de [30].....	17
Figura 5. Ejemplo PN identificada. Tomada de [16].....	18
Figura 6. Ejemplo modelo eventos reactivos. Tomado de [23].....	18
Figura 7. Estimación de tiempo de un evento. Tomada de [22]	19
Figura 8. Distribución de densidad en un evento. Tomado de [27].....	20
Figura 9. Ejemplo identificación parámetros de tiempo. Tomado de [31]	20
Figura 10. Parámetros de tiempo de cada evento. Adaptado de [11].....	21
Figura 11. Falsas alarmas por parámetro. Tomado de [5]	22
Figura 12. Algoritmo FDI. Adaptado de [16].....	23
Figura 13. Alarmas de fallos por causalidad. Tomado de [16]	24
Figura 14. Alarmas temporales. a) Alarmas temporales evento 1, b) tasa de alarmas del evento 1, c) detección de fallos del evento 1, d) alarmas temporales evento 4, e) tasa de alarmas del evento 4, f) detección de fallos del evento 4. Adaptado de [16]	25
Figura 15. FDI con media móvil. Tomado de [14].....	26
Figura 16. FDI de cada evento (en negro diag+ y en rojo diag-). a) Función de detección, b) Evento 1, c) Evento 2, d) Evento 3, e) Evento 4, f) Evento 5, g) Evento 6, h) Evento 7. Tomado de [18].....	27
Figura 17. Probabilidad de fallo de cada evento (en negro la probabilidad y en rojo diag-). a) Función de detección, b) Evento 1, c) Evento 2, d) Evento 3, e) Evento 4, f) Evento 5, g) Evento 6, h) Evento 7. Tomado de [18].....	28
Figura 18 Diagrama de flujo de Algoritmo No. 1.....	33
Figura 19. Residuales del tiempo.....	36
Figura 20. Función <i>diag +</i> , <i>diag -</i> y función de probabilidad.....	36
Figura 21. Alarmas de detección de fallo temporal algoritmo No.1	37

Figura 22. Validación de datos Algoritmo No. 1.....	38
Figura 23. Diagrama de flujo de Algoritmo No 2.....	39
Figura 24. Alarmas de detección de fallos temporales	40
Figura 25. Alarmas de detección de fallos temporales por cada evento y secuencia	41
Figura 26. Validación de datos Algoritmo No. 2.....	42
Figura 28. Caso de estudio No. 1. Tomado de [15]	47
Figura 29. Generación de eventos. Caso de estudio No. 1.....	48
Figura 30. Simulación caso de estudio No. 1.....	49
Figura 31. Fallos con diferentes niveles de intensidad. a) Nivel 10%, b) 20%, c) 30%, d) 40%, e) 50%, f) 60%, g) 70%, h) 80%, i) 90% y j) 100%.....	50
Figura 32. Planta caso de estudio No. 2. Tomada de [38].....	52
Figura 33. Modelo TPN del caso de estudio No. 2. Tomado de [38].....	52
Figura 34. Generación de eventos. Caso de estudio No. 2.....	54
Figura 35. Simulación caso de estudio No. 2.....	55
Figura 36. Fallos con diferentes niveles de intensidad. a) Nivel 10%, b) 20%, c) 30%, d) 40%, e) 50%, f) 60%, g) 70%, h) 80%, i) 90% y j) 100%.....	57
Figura 37. Modelo TPN del caso de estudio No. 3. Tomado de [14].....	60
Figura 38. Generación de eventos. Caso de estudio No. 3.....	61
Figura 39. Simulación caso de estudio No. 3.....	62
Figura 40. Fallos con diferentes niveles de intensidad. a) Nivel 10%, b) 20%, c) 30%, d) 40%, e) 50%, f) 60%, g) 70%, h) 80%, i) 90% y j) 100%.....	63
Figura 41. Fallos inducidos y detectados, caso de estudio No. 1.....	66
Figura 42. Fallos inducidos y detectados, caso de estudio No. 2.....	67
Figura 43. Fallos inducidos y detectados, caso de estudio No. 3.....	68
Figura 44. Falsas alarmas, caso de estudio No. 1.....	69
Figura 45. Falsas alarmas, caso de estudio No. 2.....	69
Figura 46. Falsas alarmas, caso de estudio No. 3.....	70
Figura 47. Sensibilidad y especificidad del algoritmo No. 1, caso de estudio No. 1.....	71
Figura 48. Sensibilidad y especificidad del algoritmo No. 2, caso de estudio No 1.....	71

Figura 49. Sensibilidad y especificidad del algoritmo No. 1	72
Figura 50. Sensibilidad y especificidad del algoritmo No. 2	73
Figura 51. Sensibilidad y especificidad del algoritmo No. 1, caso de estudio No. 3	74
Figura 52. Sensibilidad y especificidad del algoritmo No. 2, caso de estudio No. 3	74
Figura 56. Sensibilidad algoritmo 1 y 2, caso de estudio No. 1	75
Figura 57. Sensibilidad algoritmo 1 y 2, caso de estudio No. 2	76
Figura 58. Sensibilidad algoritmo 1 y 2, caso de estudio No. 3	77
Figura 59. Especificidad algoritmo 1 y 2, caso de estudio No. 1	78
Figura 60. Especificidad algoritmo 1 y 2, caso de estudio No. 2	79
Figura 61. Especificidad algoritmo 1 y 2, caso de estudio No. 3	80
Figura 62. Tiempo de ejecución por cada caso de estudio	81
Figura 63. Modelo del sistema	83
Figura 64. Modelo con comportamiento no observable	84
Figura 65. Fallos inducidos	87
Figura 66. Fallos inducidos.	88
Figura 67. Sensibilidad y especificidad algoritmo 1.	89
Figura 68. Sensibilidad y especificidad algoritmo 2.	89
Figura 70. Sensibilidad y especificidad.	90
Figura 71. Tiempo de ejecución.	91

Lista de tablas

Tabla 1. Parámetros utilizados para detección. Adaptado de [5]	21
Tabla 2. Comparación de estudios	31
Tabla 4. Escenarios de experimentación para el caso de estudio Nro 1.....	48
Tabla 5. Medidas de desempeño de todos los experimentos en el caso de estudio Nro 1.	50
Tabla 6. Evaluación de las medidas de desempeño de todos los experimentos en el caso de estudio No 1.....	51
Tabla 7. Escenarios de experimentación para el caso de estudio Nro2.....	54
Tabla 8. Medidas de desempeño de todos los experimentos en el caso de estudio Nro 2.	57
Tabla 9. Evaluación de las medidas de desempeño de todos los experimentos en el caso de estudio Nro 2	59
Tabla 10. Escenarios de experimentación para el caso de estudio Nro 3.....	61
Tabla 11. Medidas de desempeño de todos los experimentos en el caso de estudio Nro 3	63
Tabla 12. Evaluación de las medidas de desempeño de todos los experimentos en el caso de estudio No 3.....	64
Tabla 13. Escenarios de experimentación comportamiento no observable.....	85
Tabla 14. Medidas de desempeño de todos los experimentos	85

1 Introducción

Los sistemas dinámicos se pueden clasificar en: sistemas en tiempo continuo y se representan mediante ecuaciones diferenciales, en tiempo discreto y se suelen representar mediante ecuaciones en diferencia y si las variables pueden cambiar en cualquier momento se denominan de eventos discretos (DES). Históricamente, los científicos e investigadores se han concentrado en estudiar fenómenos que están regidos por leyes físicas o naturales, pero en la vida cotidiana se depende cada vez más de comportamientos discretos; es así como muchos fenómenos que suceden, dependen de eventos instantáneos como presionar un botón, presionar una tecla, el encendido de maquinaria [1]; así como en la práctica de la ingeniería, muchos actuadores, como interruptores, válvulas, etc., cambian de acuerdo a acciones específicas, y su aplicación incluye procesos industriales, sistemas de producción y robótica, entre otros. Existen diferentes sistemas que se pueden modelar como DES tales como: procesos de fabricación, sistemas de tráfico, procesos biológicos y químicos [2], redes de telecomunicaciones [3], entre otros.

En este escenario, las herramientas formales para modelar, analizar y controlar sistemas de automatización pueden proporcionar soluciones eficientes. En particular, los sistemas de eventos discretos, modelados como autómatas de estado finito (FSA) o como redes de Petri (PN), representan una opción lógica para evaluar los sistemas que cambian de acuerdo con la ocurrencia de eventos [1].

A medida que los sistemas se vuelven más complejos, los fallos¹ aparecen con mayor frecuencia y luego las consecuencias son potencialmente graves; como resultado, el diagnóstico de fallos se ha convertido en una tarea extremadamente importante en muchas aplicaciones reales.

¹ Un fallo es una desviación del comportamiento del sistema requerido por su especificación

El proceso de diagnóstico en un DES permite medir la capacidad que tiene el modelo del sistema para determinar, durante un tiempo finito, la presencia de eventos anómalos no observables (fallos), utilizando el registro de eventos observados. El proceso de diagnóstico detecta, aísla y caracteriza un comportamiento anormal o fallo en un sistema [4]; puede ser aplicado con el fin de poner a prueba el sistema con las funciones que normalmente realiza y/o podría realizar. Se pueden encontrar dos tipos de fallos, uno asociado directamente con los eventos y otro asociado al tiempo que transcurre por cada evento sucedido [5], es decir fallos en eventos temporizados. Los eventos temporizados se caracterizan porque el tiempo transcurrido entre eventos es estocástico o determinístico; los tiempos estocásticos usualmente utilizan funciones de densidad de probabilidad (pdf) como distribución normal, distribución normal con sesgo positivo o negativo, triangular simétrica, señal cuadrada, exponencial o polinómica [2], [5], [6], con el fin de ampliar el valor típico o permisivo que tomará el tiempo como variable aleatoria.

El alcance de los métodos de diagnóstico depende de si realiza detección (FD) o detección y aislamiento (FDI) o detección, aislamiento y caracterización. La detección corresponde a saber si se produjo o no un fallo; detección y aislamiento, la capacidad de conocer un comportamiento no normal y encontrar el componente donde ha ocurrido y por último se encuentra la caracterización que representa, aparte de identificar el fallo y encontrarlo, saber el tipo y calcular la magnitud de su afectación en el sistema [4].

Los métodos de diagnóstico de fallos en sistemas modelados como DES estocásticos, tienen la capacidad de determinar durante un determinado tiempo finito, la existencia de eventos anormales, por medio del análisis del tiempo observado entre eventos [2], [5]. Esto puede describir componentes defectuosos, desgaste en piezas, lecturas de sensores con retraso en tiempo, información que se transmite en forma tardía, entre otros procesos que dependan del tiempo [7], [8]. El diagnóstico de fallos en sistemas temporizados se basa en detectar cuando se genera un evento fuera del intervalo de tiempo asociado a este, sin generar falsas alarmas, aislar para saber de manera precisa el evento o eventos dónde ocurre el fallo temporal [9] y por último caracterizarlo con el fin de conocer la forma como

se genera y cuál es la magnitud de afectación en el sistema [10], proceso que generalmente se realiza por juicio de expertos.

Muchas de las soluciones para el diagnóstico de fallos en sistemas modelados como DES estocásticos, bajo los formalismos de autómatas temporizados (TA) y redes de Petri temporizadas (TPN), se han enfocado en la detección a partir de algoritmos que comparan el conjunto de eventos de entrada con un modelo con comportamiento libre de fallo [11], utilizando cadenas de Markov para determinar la probabilidad de suceso de un fallo, o con un modelo que se deriva del gráfico de alcanzabilidad de la PN se representa los aspectos de tiempo y probabilidad de la evolución del marcado [12]. El conjunto de eventos de entrada observado, tienen como característica principal la distancia temporal entre los eventos y se considera fallo cuando hay un cambio del tiempo entre eventos estudiado. En [13] y [14], la información temporizada de los eventos se ha trabajado a partir de rangos (tiempo mínimo y máximo entre eventos) o a partir de ciertas funciones de densidad de probabilidad. Estos métodos, permiten identificar si el sistema está en modo de fallo o en modo normal, pero no permiten determinar qué evento específicamente está generando el comportamiento no deseado y con ello llegar a localizar un componente defectuoso, o un desgaste progresivo. Algunas propuestas que incluyen aislamiento como las presentadas en [15], [16], trabajan con fallos predefinidos, esto implica la posibilidad de no detectar los fallos que no se tuvieron en cuenta con anterioridad. Los fallos predefinidos son todos los posibles fallos del sistema que según su dinámica, puede llegar a suceder; pero existe el riesgo que ocurra un fallo que no se haya considerado que corresponda a un proceso anormal y poco recurrente, esto da cabida a mal diagnóstico [2]. Otra forma de detectar el fallo es la presentada en [17], se basa en el análisis de los comportamientos consistentes y permite calcular el intervalo de tiempo más probable donde se produjo el fallo; pero no permite determinar el componente del sistema que falló.

En los estudios analizados se encuentran dos propuestas para la detección y aislamiento de fallos, una se basa en la comparación del tiempo observado frente a un rango establecido para cada evento o secuencia, usando media móvil [14] y la otra basada en residuales del

tiempo observado [18]. En la literatura reportada no existe evidencia que permita establecer cuál tendencia tiene mejor desempeño, ni en qué ámbito se puede aplicar con el objeto de tener mejores resultados en la detección y aislamiento de fallos temporizados.

Teniendo en cuenta lo anterior, se planteó en la presente investigación, la comparación de dos métodos de identificación de fallos en DES temporizados estocásticos frente a la capacidad de detectar y aislar fallos bajo el formalismo de redes de Petri temporizadas estocásticas.

Los métodos de detección considerados fueron: en primer lugar la propuesta presentada en [14] debido a que trabaja el proceso de detección y aislamiento de fallos por medio de un análisis de la media y la desviación estándar de los tiempos de cada evento y la propuesta presentada en [18] con un trabajo basado en residuales de tiempo de los eventos. Estos trabajos resaltan por su importancia para ser evaluados en su desempeño para ser aplicables en diferentes entornos.

Generando la siguiente pregunta de investigación que condujo el estudio:

¿Qué ventajas o desventajas presenta el método de diagnóstico de fallos propuesto por [14] frente al método presentado en [18] a partir de la capacidad para detectar y aislar fallos en DES temporizados estocásticos?

Para dar solución a este interrogante, los objetivos planteados fueron:

Objetivo general

Comparar el desempeño de dos algoritmos de detección de fallos en sistemas de eventos discretos temporizados estocásticos a partir de su eficiencia para detectar y aislar el fallo, detectar falsas alarmas y costo computacional.

Objetivos específicos

- Implementar los algoritmos de detección de fallos a considerar en el estudio.

- Establecer un protocolo de experimentación y los indicadores de desempeño de los algoritmos seleccionados de detección de fallos relacionados con detección, aislamiento y costo computacional.
- Determinar el desempeño de los algoritmos a partir de señales de DES temporizados estocásticos.

El documento está organizado de la siguiente manera, en el capítulo 2 se realiza la revisión de la literatura relacionada con el tema de investigación: Diagnóstico de fallos en DES estocásticos, en el capítulo 3 se describe el proceso metodológico llevado en el estudio, el capítulo 4 muestra todos los resultados obtenidos en el proceso de experimentación, en el capítulo 5 se analizan los resultados obtenidos y su relevancia en la investigación con su enfoque, y por último en el capítulo 6 se abordan las conclusiones del trabajo con recomendaciones para futuras investigaciones.

2 Revisión de literatura

2.1 Marco Conceptual

Para el desarrollo de la investigación se deben tener en cuenta los siguientes conceptos:

Definición 1. DES: Discrete Event System o Sistema de Eventos Discretos, son sistemas dinámicos representados a través de un conjunto de variables de estado que describen la situación de un sistema en el tiempo y que cambian en puntos discretos a partir de eventos.

Definición 2. PN: Petri Net o Red de Petri, es un formalismo de modelado para representar a un sistema de eventos discretos compuesto por transiciones y lugares que a su vez están asociados a eventos y estados del sistema respectivamente.

La estructura de una red de Petri (PN), N es un grafo bipartito representado por una quintupla $N = (P, TR, Pre, Post, M_0)$ donde P es el conjunto de lugares con cardinalidad np , TR es el conjunto de transiciones con cardinalidad ntr , y $Pre: P \times TR \rightarrow Z$, $Post: TR \times P \rightarrow Z$ son las matrices de incidencia Pre y Pos respectivamente, que especifican arcos que conectan los lugares y transiciones. La matriz $C = Post - Pre$ es la matriz de incidencia de $np \times ntr$. La función de marcado $M: P \rightarrow Z$ representa el número de marcado de cada lugar, y M_0 es el marcado inicial [19].

Definición 3. IPN: Interpreted Petri Net o Red de Petri Interpretada, es una extensión de una red de Petri con el fin de representar el conjunto de señales de entrada y salida (E/S) del sistema, asociadas con las transiciones y lugares respectivamente.

Una Red de Petri Interpretada (IPN) es una tupla $Q = (N, U, Y, \lambda, \varphi)$, donde N es una PN, $U = \{u_0, \dots, u_{2^m-1}\}$ es el alfabeto de entrada, u_s un símbolo de entrada, y m es el número de entradas; $Y = \{y_0, \dots, y_{2^n-1}\}$ es el alfabeto de salida, y_j es un símbolo de salida, y n es el número de salidas; $\lambda: TR \rightarrow U$ es la función de etiquetado que asigna a cada transición

un símbolo de entrada, y $\varphi: P \rightarrow Y$ es la función que asigna un símbolo de salida a cada lugar.

El alfabeto del sistema Ω relaciona los símbolos de I/O; específicamente, $\Omega = U \cdot Y$. Por lo tanto, un evento ω tal que $\omega \in \Omega$, tiene la forma $\omega = u_s y_j$.

Definición 4. T-IPN: time Interpreted Petri Net o Red de Petri Interpretada temporizada, es una extensión de la Red de Petri Interpretada que tiene asociado a sus transiciones o lugares un intervalo de tiempo de duración.

Una t-IPN es una estructura $stQ = (Q, \Omega, \delta)$ donde $Q = (N, U, Y, \lambda, \varphi)$ es una IPN N, U, Y tiene el mismo significado de la Definición 4, pero la función de entrada λ es definida por $\lambda: TR \rightarrow U$. δ como una función de etiquetado que asigna un símbolo de entrada y una función de densidad a cada transición.

2.2 Estado del arte

La metodología utilizada para realizar la búsqueda de antecedentes en la literatura fue basado en [20] con el propósito de encontrar artículos científicos relacionados con diagnóstico de fallos temporales en DES. Las cadenas de búsqueda utilizadas en forma general son: (discrete event system) AND (diagnosis) AND (timed OR stochastic) AND (fault OR failure). Las bases de datos científicas utilizadas son: Science Direct, IEEE Xplore Digital Library, SCOPUS, SpringerLink y Taylor & Francis.

En el proceso de selección se tomaron los artículos que estaban relacionados con diagnóstico de fallos temporales en DES, publicados entre el año 2013 al 2023, escrito en idioma inglés, como criterios de inclusión y se excluyen los que no estén relacionados con detección, aislamiento o caracterización de fallos temporales en DES. Después de definir los criterios de inclusión y exclusión se seleccionaron los artículos por medio de su resumen y aquellos estudios relevantes con un análisis con mayor profundidad, considerando también

sus referencias. En la Figura 1 se resume las bases de datos consultadas con el número de artículos encontrados siguiendo la metodología descrita en este capítulo.

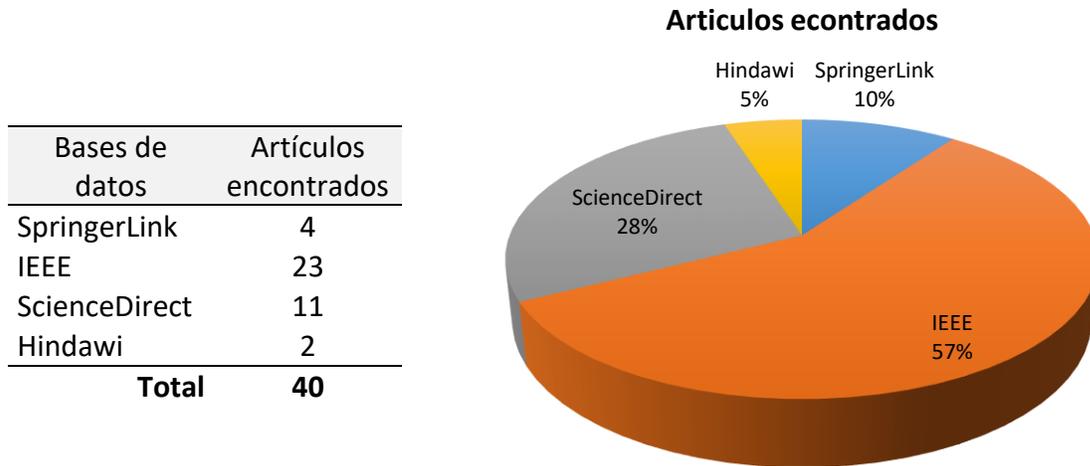


Figura 1. Bases de datos consultadas

2.3 Modelado de sistemas de eventos discretos temporizados a partir de métodos de identificación

Los sistemas que pueden ser modelados como DES, se ven afectados por condiciones de entrada que varían de manera aleatoria y que conllevan a comportamientos estocásticos en la generación de los eventos. Este tipo de sistemas con eventos que se generan respetando un intervalo de tiempo, se modelan como DES temporizados. En los estudios sobre DES temporizados, se encuentran los sistemas que tienen una dinámica Markoviana y los No Markovianos. La dinámica Markoviana comprende aquellos procesos que permiten describir, mediante probabilidades, las transiciones entre estados del sistema, es decir, se determina la probabilidad condicional de transición de pasar a otro estado, dado que suceda el estado actual; en la dinámica No Markoviana, se desconoce la información pasada y/o futura de las transiciones entre estados del sistema, para esto es necesario representar como un proceso estacionario o recurrente [6].

Una forma de hallar el modelo en este tipo de sistemas es a partir de procesos de identificación con base en la observación del tiempo en el cual se generan las señales. Los métodos de identificación temporizados permiten construir modelos basados en datos del sistema, que tengan una aproximación al comportamiento real del sistema [21].

Los métodos de identificación en DES temporizados se basan en dos formalismos: Redes de Petri temporizadas (TPN), o Autómatas temporizados (TA).

El proceso de identificación temporizado se divide en 3 etapas como se observa en la Figura 2, la primera consiste en generar el conjunto de eventos a partir del cambio en las señales de sensores y actuadores; es decir, la información de entrada y salida del sistema respectivamente, en la segunda etapa se enfoca en realizar el modelo a partir del conjunto de eventos que se aproxime al comportamiento real del sistema, por último, identificar la información de tiempo asociada a cada evento generado.

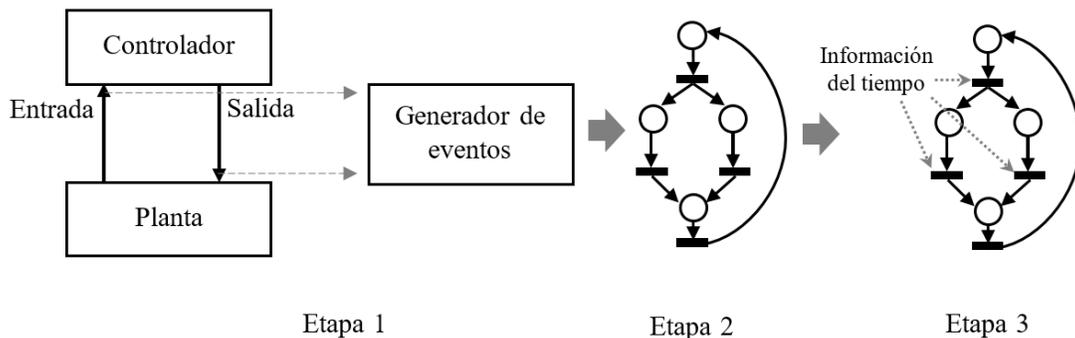


Figura 2. Proceso de identificación

En la etapa 1 se genera el conjunto de eventos de acuerdo a la información del sistema. En los estudios [5], [21]–[28], se obtiene dicho conjunto de eventos observados de las E/S (Definición 3) del sistema expresada en forma lógica y a su vez cada conjunto de señales representa un evento nuevo cuando hay un cambio en estas señales. Como se puede ver en la Figura 3 las señales de entrada al controlador son entregadas por los sensores del sistema y las salidas por los actuadores. El conjunto de entradas y salidas del sistema corresponden a un evento asociado que a su vez tiene un tiempo de duración, cada cambio de conjunto de señales genera un nuevo evento o también se repite un evento ya generado.

Los eventos representan un comportamiento del sistema que evoluciona en el transcurso del tiempo.

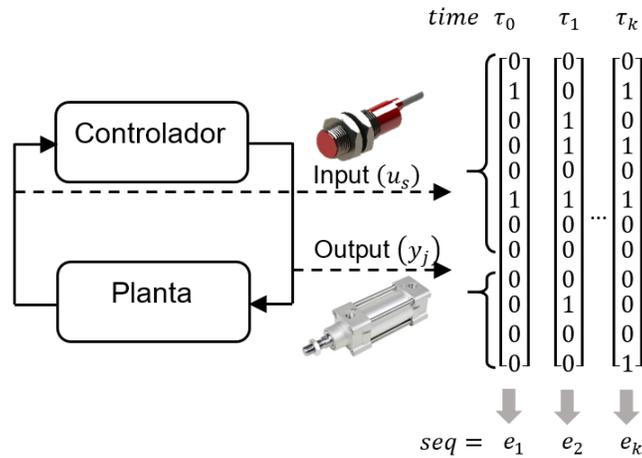


Figura 3. Generador de eventos

Lo anterior es similar a [29] que observa el conjunto de señales de la salida, generando una PN interpretada (IPN) supervisada por un experto. Por otro lado, en [30] se identifica el conjunto de eventos al existir un cambio en alguna señal en los sensores y que exista una variación en la salida del sistema, de esta manera se analiza la ocurrencia de una causa en entrada y su efecto sobre la salida. En este estudio después de identificar el conjunto de eventos se centra en el enfoque reactivo del controlador denominado así por los autores al conjunto de señales de salida que tienen un cambio y que pertenecen al conjunto de eventos como se muestra en la Figura 4, W es el conjunto de señales de entrada y salida del sistema, E representa los cambios de señales en W llamados eventos y los eventos que tienen cambios en la salida representan al conjunto de eventos reactivos RE .

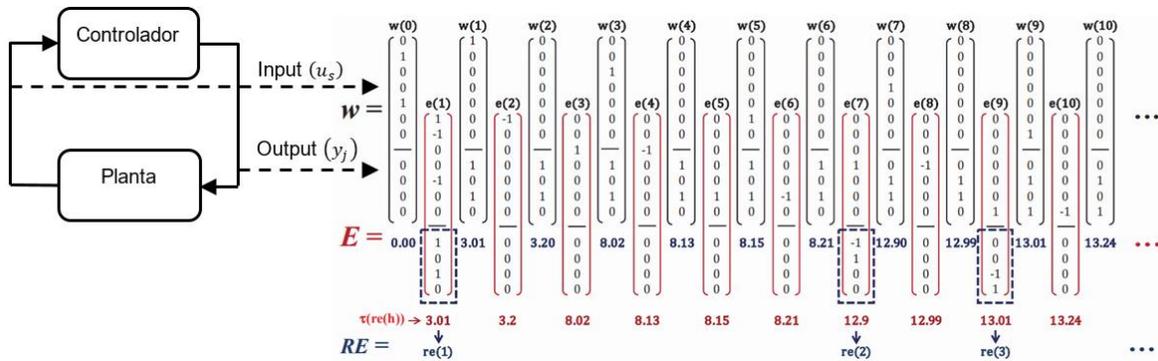


Figura 4. Eventos reactivos. Adaptada de [30]

Después de identificar el conjunto de eventos se construye el modelo que se aproxime al comportamiento real del sistema (etapa 2 de la Figura 2), en los trabajos realizados en [21], [25], [29], los estudios cuentan con un experto que genera un modelo previamente y la identificación está basada en comparar el conjunto de eventos obtenido con la evolución de la PN. La evolución de la PN está compuesta por transiciones asociadas a los eventos que se activan y lugares que cambian de estado, estos cambios deben coincidir con el conjunto de eventos identificado; cuando el conjunto de eventos no coincide con el modelo diseñado por el experto se analiza si el conjunto de eventos corresponde al comportamiento del sistema y en ese caso se modifica el modelo inicial.

En [22], [28] se genera una PN, donde los lugares corresponden a cada estado y transiciones para cada evento. El conjunto de eventos identificados debe estar relacionado con el cambio de estados y la evolución de la PN. La PN de la Figura 5 genera dos secuencias de eventos $seq_1 = (e_1 e_2)$ o $seq_2 = (e_1 e_3 e_4)$, estas secuencias deben coincidir con las secuencias de eventos generados en el proceso de identificación en la etapa 1.

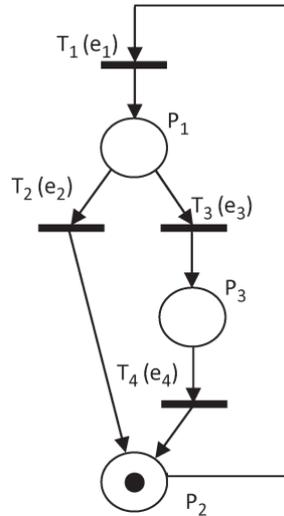


Figura 5. Ejemplo PN identificada. Tomada de [16]

En [5], [26], [27] comparte la misma lógica de generación del modelo descrita anteriormente pero el resultado es un FSA. Para el modelo de [23] se utilizan los eventos reactivos de la Figura 4 para generar la PN, esto depende del cambio del conjunto de señales de salida del sistema dando como resultado estructuras que se muestran en Figura 6.

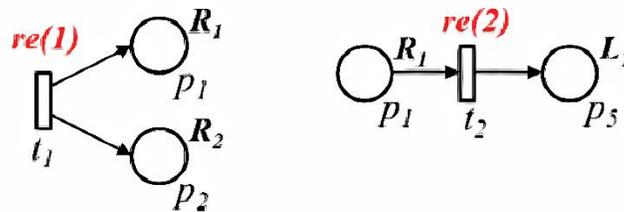


Figura 6. Ejemplo modelo eventos reactivos. Tomado de [23]

Para [30] cada diferencia entre el conjunto de señales de sensores siguiente y la anterior, se asocia a un estado y transición de una PN. El algoritmo de identificación de [24] consiste en construir las proposiciones lógicas a partir del comportamiento del conjunto de eventos observada y se transforman en desigualdades enteras, para posteriormente dar solución con programación lineal de enteros mixtos.

Una vez se ha obtenido el modelo en la etapa 3 del proceso de identificación (ver Figura 2), se realiza la identificación de las características de tiempo del modelo previamente encontrado. En la etapa en [22]–[24], [29], [30] registran el tiempo que tarda cada evento

o transición de la PN y con esta información se establece un rango aproximado del evento en el sistema real; la precisión de esta aproximación depende de la cantidad de observaciones del sistema, como se muestra en la Figura 7. En la Figura 7 se observa el cómo el tiempo promedio de un evento se estabiliza a medida que se aumenta el número de muestras, tratándose de estabilizarse después de 30 muestras, teoría que obedece a las simulaciones de Montecarlo.

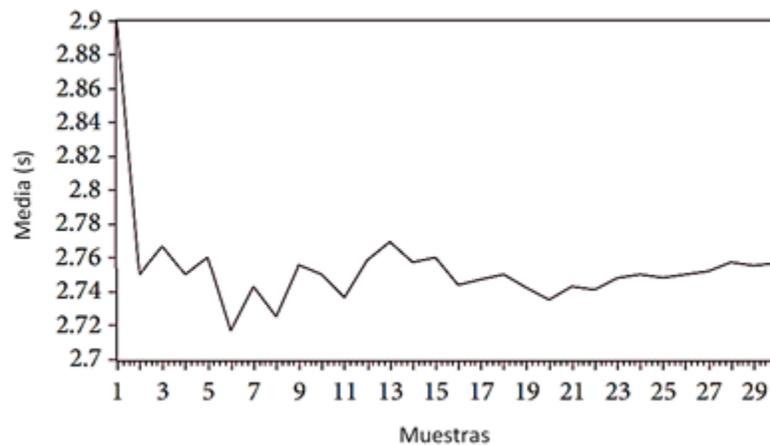


Figura 7. Estimación de tiempo de un evento. Tomada de [22]

Por otra parte se encuentran los estudios [26]–[28], que determinan por medio de los eventos generados, un modelo estadístico que describe el comportamiento de cada transición con una función de densidad de probabilidad, esto se lleva a cabo con observaciones del sistema hasta obtener un margen de error aceptable definido por el estudio. Las funciones de densidad de probabilidad (pdf) identificadas se pueden ver en Figura 8 y Figura 9a, en la Figura 9 también se evidencia la cantidad de observaciones necesarias para realizar la identificación de los parámetros de tiempo en el estudio [31].

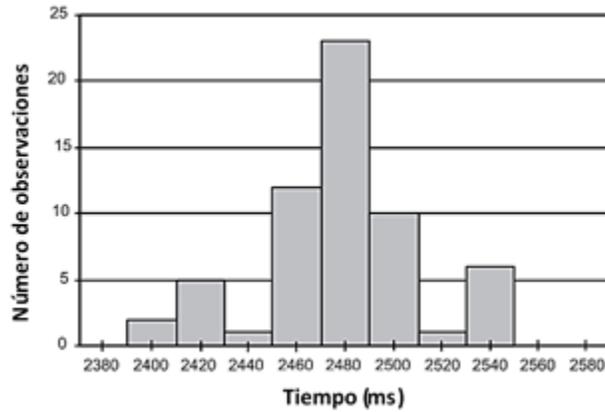
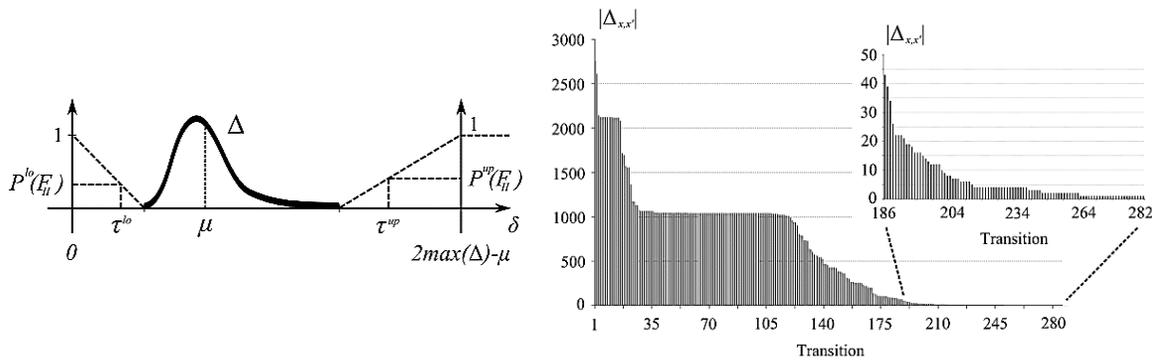


Figura 8. Distribución de densidad en un evento. Tomado de [27]



a) Distribución de densidad identificada en un evento.

b) Cantidad de observaciones por transición

Figura 9. Ejemplo identificación parámetros de tiempo. Tomado de [31]

Una aplicación de los modelos temporizados identificados es que apoyen en la detección de fallos, es decir, obtener modelos que permitan calcular la probabilidad de ocurrencia de fallos en DES utilizando el conjunto de eventos observados temporizados.

2.4 Detección y aislamiento de fallos temporales en DES

En sistemas de fabricación donde se combinan varios procesos con maquinaria o recursos compartidos, existen desviaciones temporales que afectan al sistema en general, generando un comportamiento que se desvía del objetivo previsto. En este ítem se aborda el proceso de detección y aislamiento de esas desviaciones temporales que pueden afectar

al comportamiento de un sistema de fabricación en masa o similar, que puede ser modelado con las características de tiempo del sistema real. Con ayuda del modelo identificado del sistema se puede determinar si se produce un comportamiento anormal, conocido como fallo. Los métodos de detección tienen como propósito conocer si se produjo un evento de fallo y el momento en el que ocurre, en el caso de métodos de aislamiento, su propósito es determinar en el sistema donde ocurre el fallo.

Entre las técnicas utilizadas para detección se encuentran el análisis de la media y desviación estándar del tiempo que dura cada evento con respecto al tiempo del evento a evaluar, por ejemplo en [11] se identifica la función de densidad de probabilidad (pdf) del tiempo de cada tiempo del evento con una distribución normal, en la Figura 10 están los límites de cada evento en su comportamiento libre de fallo. El proceso de detección de este estudio se basa en analizar cada uno de los eventos de prueba con los límites (mínimo y máximo) de tiempo identificados en cada evento para comprobar la ocurrencia de un fallo.

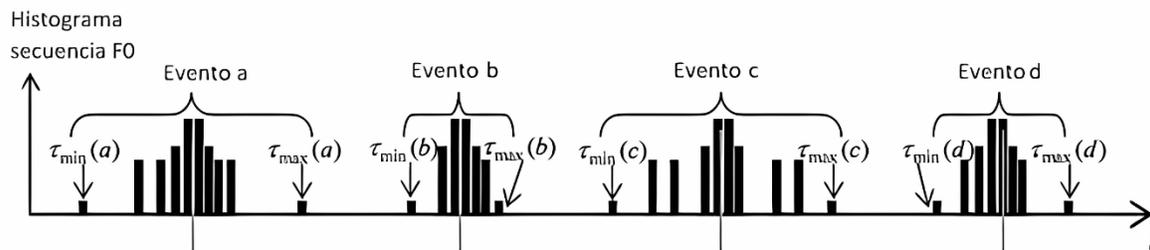


Figura 10. Parámetros de tiempo de cada evento. Adaptado de [11]

Con algunas semejanzas el estudio [5] compara cada tiempo del evento con los límites definidos, en la Tabla 1 se presentan los límites y los parámetros usados. Donde Δ representa las observaciones de tiempo, μ es el promedio, s la desviación estándar, v ajusta el tamaño del intervalo de acuerdo con un número esperado de observaciones dentro de estos límites, γ y ϵ son parámetros de adaptación y extensión respectivamente.

Tabla 1. Parámetros utilizados para detección. Adaptado de [5]

Parámetro	Límite inferior	Límite superior
Min / Max	$\tau^{lo} = \min \Delta$	$\tau^{up} = \max \Delta$

Parámetro	Límite inferior	Límite superior
Distribución normal	$\tau^{lo} = \hat{\mu} - \nu \hat{\sigma}$	$\tau^{up} = \hat{\mu} + \nu \hat{\sigma}$
Adaptación de sesgo a la derecha	$\tau^{lo} = \min \Delta - \gamma \epsilon (\max \Delta - \min \Delta)$	$\tau^{up} = \min \Delta + \epsilon (\max \Delta - \min \Delta)$
Adaptación de sesgo a la izquierda	$\tau^{lo} = \min \Delta - \gamma \epsilon (\max \Delta - \min \Delta)$	$\tau^{up} = \min \Delta + \epsilon (\max \Delta - \min \Delta)$
Adaptación sin sesgo	$\tau^{lo} = \min \Delta - \epsilon (\max \Delta - \min \Delta)$	$\tau^{up} = \min \Delta + \epsilon (\max \Delta - \min \Delta)$

Los valores dados a γ determinan una adaptación de simetría al agregar una tolerancia al intervalo $\max \Delta - \min \Delta$ y ϵ aumenta la robustez de la detección de fallos contra la influencia de perturbaciones como se puede apreciar en Figura 11; la cantidad de falsas alarmas se reducen significativamente con algunos parámetros considerados como error tipo I (considerar a un evento como fallo cuando no lo es, también denominado falso positivo). Las falsas alarmas se consideran detecciones de fallos en eventos que se encuentran en los parámetros normales, es decir, detecciones fallos equivocadas.

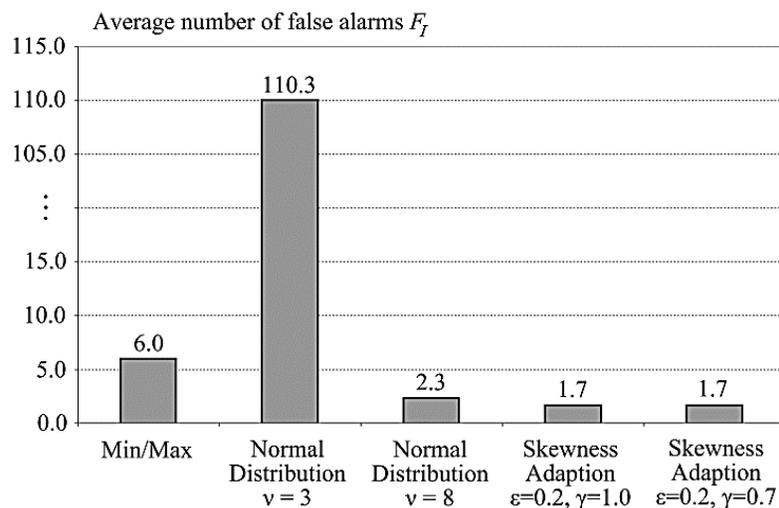


Figura 11. Falsas alarmas por parámetro. Tomado de [5]

También se encuentra [16] con el trabajo realizado en detección y aislamiento (FDI) de fallos temporales, en la Figura 12 se encuentra el algoritmo FDI. En el primer paso se puede apreciar el proceso descrito en la etapa 1 de generación de eventos (ver Figura 2). En segundo paso se analiza que el conjunto de eventos a evaluar concuerde con el conjunto de eventos ya identificados y libre de fallos, en caso de que un evento no coincida con el conjunto de eventos, se considera un fallo por causalidad y debido a que el análisis se realiza evento por evento, también se realiza el aislamiento de dicho fallo; además analiza si el tiempo de dicho evento se encuentra entre los parámetros de tiempo identificado. Por último, se analiza que concuerden los tiempos de cada evento que se encuentra en el conjunto de eventos con los parámetros de tiempo definidos (ver Figura 14).

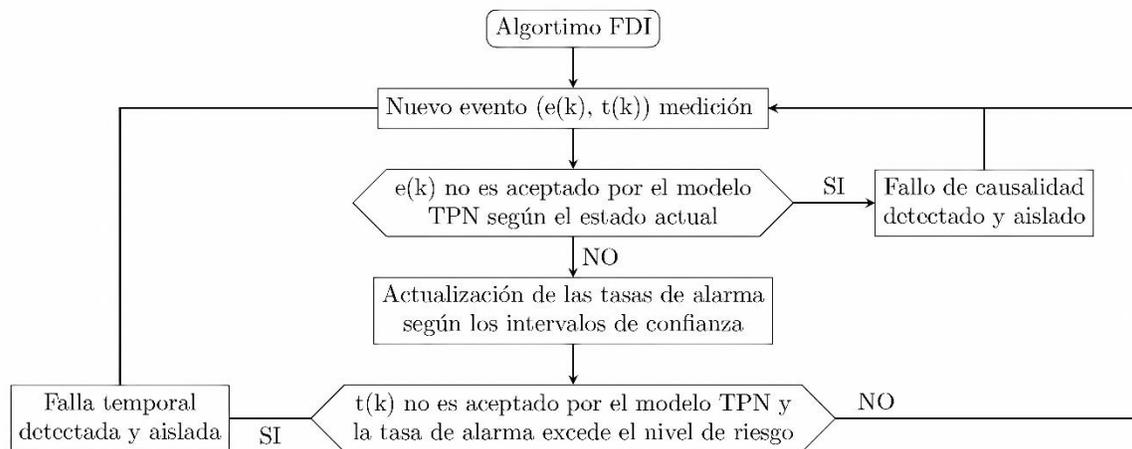


Figura 12. Algoritmo FDI. Adaptado de [16]

La Figura 13 muestra las alarmas generadas por eventos que se encuentran en el conjunto de eventos identificado. El algoritmo FDI hace una evaluación 1000 eventos, las alarmas toman valores de 0 y 1 para aquellos eventos que se están en el conjunto de eventos y los que no coinciden con el conjunto identificado.

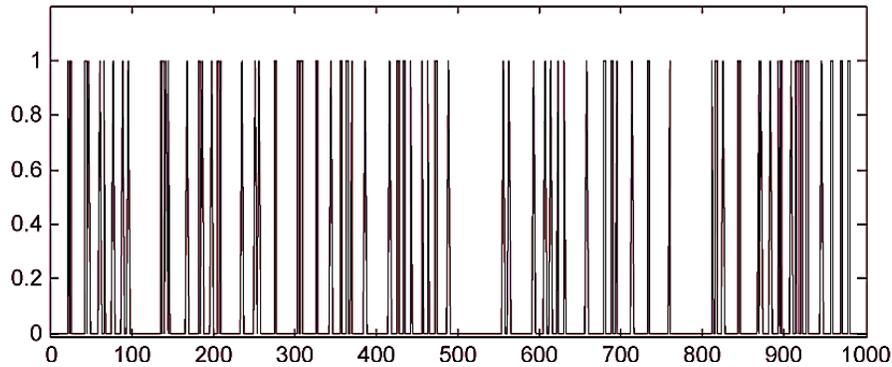


Figura 13. Alarmas de fallos por causalidad. Tomado de [16]

Los datos mostrados en la Figura 14 (a) y (d) representan las alarmas que se generan en dos eventos, en (b) y (f) están las tasas de alarmas generadas por los dos eventos y en línea punteada se representa el umbral que determina si ocurre o no un fallo, en el caso de (b) se observa que en ningún instante supera el umbral pero el caso de (f) en varias ocasiones sobrepasa el umbral definido; por último en (c) y (f) se encuentra las detecciones de fallos en los dos eventos, en el caso de (c) no hay ninguna detección y en (f) se muestran los instantes dónde ocurre los fallos. Cómo el algoritmo realiza el proceso evento por evento, al detectar el fallo inmediatamente realiza el aislamiento.

El intervalo de tiempo considerado en este estudio está definido por $TI = [\max(0, m_j - 3\sigma_j), m_j + 3\sigma_j]$, donde j representa cada evento, m la media aritmética del tiempo y σ la desviación estándar.

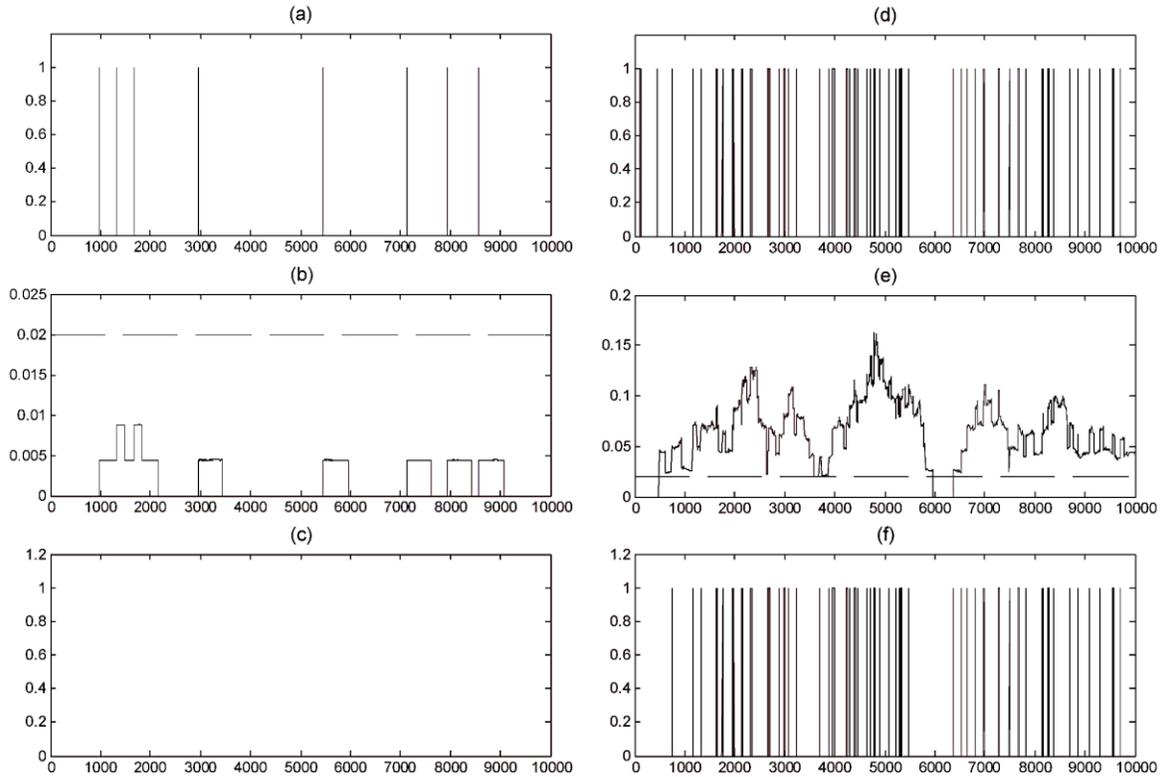


Figura 14. Alarmas temporales. a) Alarmas temporales evento 1, b) tasa de alarmas del evento 1, c) detección de fallos del evento 1, d) alarmas temporales evento 4, e) tasa de alarmas del evento 4, f) detección de fallos del evento 4. Adaptado de [16]

Por otro lado se encuentra el caso del estudio [32], que determina la probabilidad de las trayectorias en una PN y como consecuencia del estudio encuentra la probabilidad de ocurrencia de un fallo temporal en un modelo PN estocástico. En [14] los autores usan la media móvil con el tiempo de los eventos y analiza los eventos que superan la media del tiempo identificado, como muestra la Figura 15, en (a) se encuentra la media móvil del tiempo con los límites superior e inferior definidos como la $m_c \pm 0.5\sigma_c$ donde m_c y σ_c representa la media aritmética y la desviación estándar del tiempo respectivamente. También se puede apreciar que en el instante $15000TU$ se excede el límite superior y la alarma también se refleja en la desviación estándar al mismo instante.

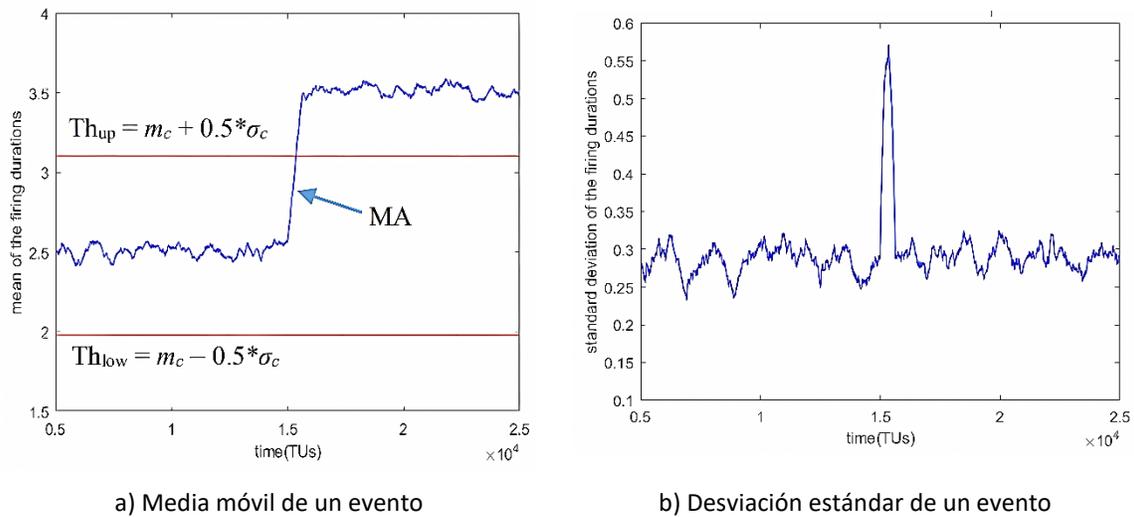


Figura 15. FDI con media móvil. Tomado de [14]

Otro enfoque de detección y aislamiento de fallos temporizados se relaciona con el concepto de residuales. El estudio presentado por [18] está basado en residuales con la información del tiempo de cada evento. El residual se determina por medio de la diferencia entre la media aritmética del tiempo con el tiempo observado de cada evento. Para el proceso de detección y aislamiento de fallos se deben tener en cuenta dos términos denominados por los autores como $diag^+$ y $diag^-$, determinados por el máximo y el mínimo conjunto de valores entre los valores promedios de tiempo, las trayectorias elementales de tamaño mínimo (MSET) y el conjunto de trayectorias que forman un estado observador de trayectoria elemental. MSET es el conjunto de trayectorias o ciclos que se forman en la evolución de la PN. En Figura 16, (a) se encuentra la función de detección donde se generan las alarmas de detección de todos los fallos temporales y en azul está el umbral de detección, las detecciones que superen el umbral definido se consideran un fallo. La función $diag^+$ no es suficiente para aislar el fallo (ver Figura 17). Esto se debe a que T_2 (Figura 17c) ocurre en trayectorias elementales de tamaño mínimo con otras transiciones, es decir, que también se generan alarmas en las transiciones T_1 , T_3 , T_4 y T_5 porque pertenecen a una secuencia o ciclo. Por eso, estas transiciones también generan una alarma de detección de fallo. El uso adicional de la función $diag^-$ confirma que el fallo afectó a T_2 (ver Figura 16c y Figura 17c).

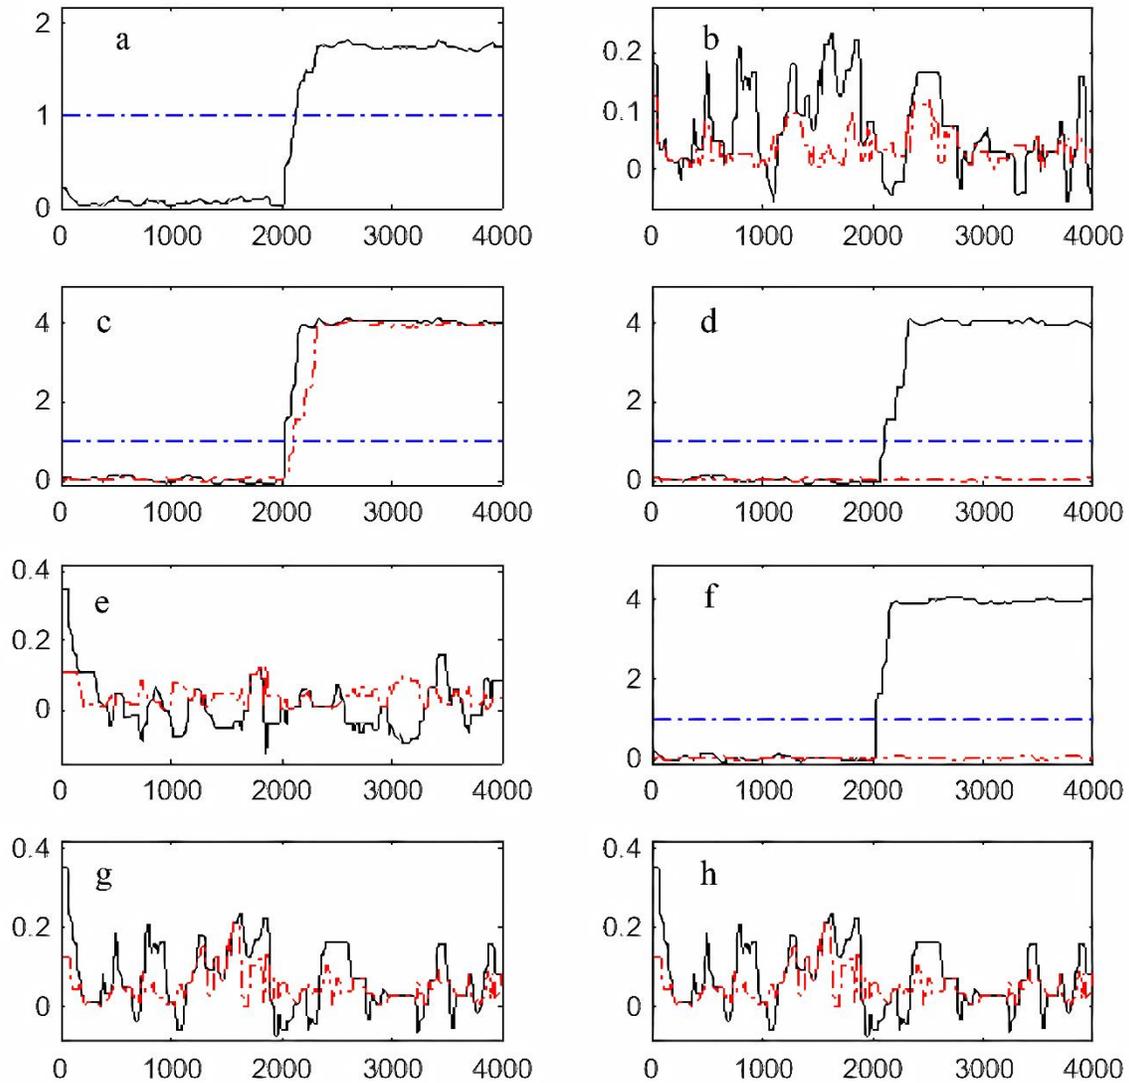


Figura 16. FDI de cada evento (en negro $diag^+$ y en rojo $diag^-$). a) Función de detección, b) Evento 1, c) Evento 2, d) Evento 3, e) Evento 4, f) Evento 5, g) Evento 6, h) Evento 7. Tomado de [18]

La función $diag^-$ por sí sola, no indica claramente el evento de fallo, pero para casos más complicados, se requieren las dos funciones ($diag^+$ y $diag^-$). Esto se confirma con las probabilidades que se muestran en Figura 17 además de los residuales $diag^-$. El evento se aísla, ya que la probabilidad se aproxima a 1 en Figura 17c.

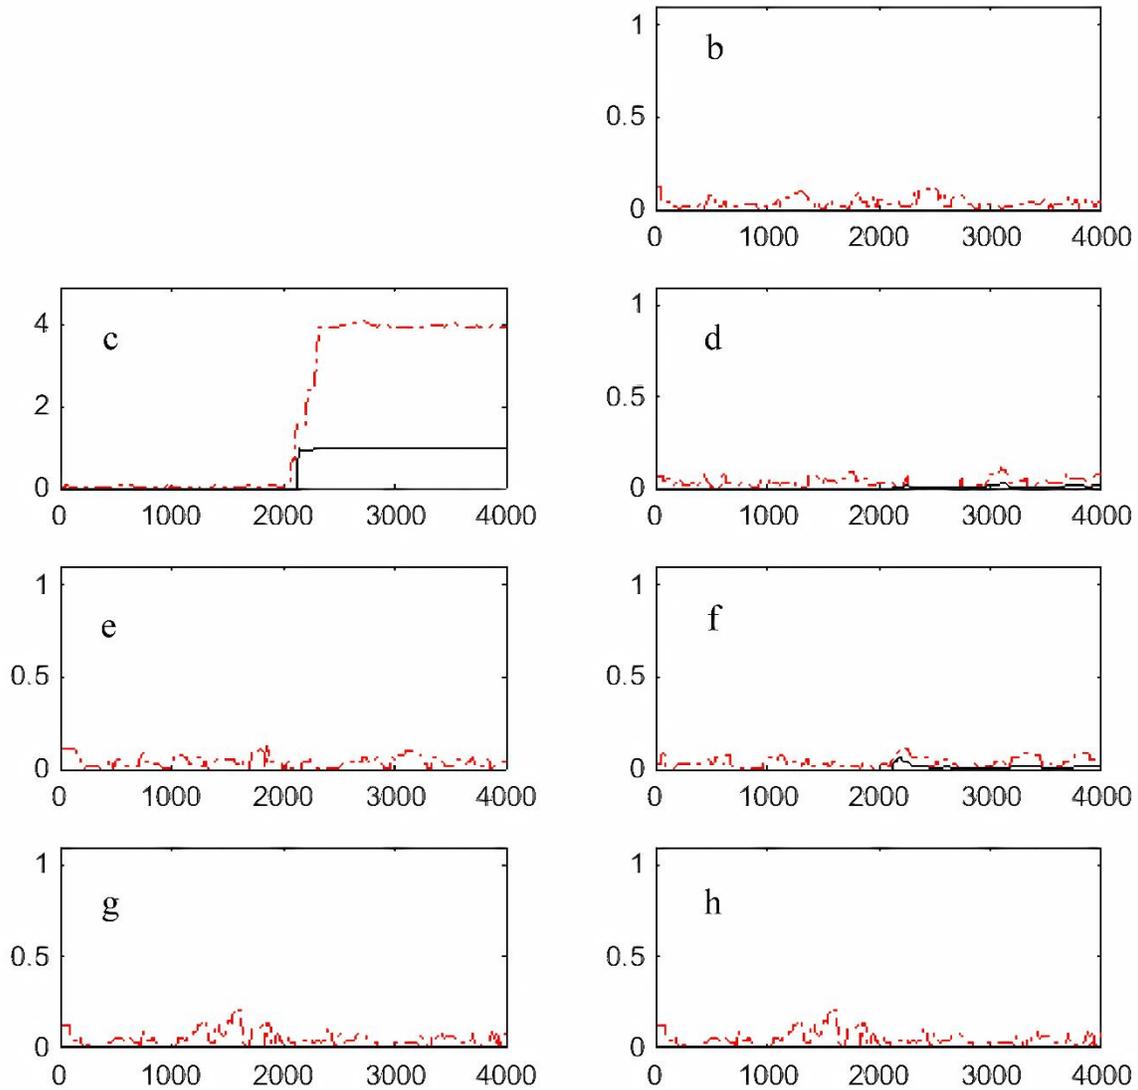


Figura 17. Probabilidad de fallo de cada evento (en negro la probabilidad y en rojo diag-). a) Función de detección, b) Evento 1, c) Evento 2, d) Evento 3, e) Evento 4, f) Evento 5, g) Evento 6, h) Evento 7. Tomado de [18]

También se encuentra [17] que realizan un análisis de la función de densidad de probabilidad (pdf) del tiempo de cada uno de los eventos y compara si el tiempo del evento a evaluar se encuentra en los parámetros establecidos por la pdf; y por último se encuentra [33] con un análisis del árbol de alcanzabilidad, donde desde el marcado actual obtiene el

conjunto de transiciones posteriores y realiza detección al encontrar la probabilidad de ocurrencia de fallo.

Para el aislamiento en [5], [11], [14], [16], [17] utilizan técnicas de comparación de las características temporales de cada evento a evaluar con los eventos identificados, de esta manera, al comparar los eventos uno a uno se puede determinar si cumple con el orden del conjunto de eventos y la similitud de sus características temporales con la de los eventos identificados y supervisado por un experto. El experto realiza el papel de verificar el proceso realizado, así como tomar decisiones en situaciones específicas.

2.5 Eficiencia en la detección y el aislamiento temporizado en DES.

En la revisión de los antecedentes de la literatura se encuentra estudios que evalúan el modelo DES de un sistema dinámico [34] por medio de un análisis de falsos positivos; los falsos positivos son el resultado de un experimento considerado como anormal cuando este resultado debería ser denominado como normal. En este estudio se utiliza para analizar la ocurrencia simultánea de eventos en el modelo TPN. De igual manera se encuentra [35] realizando un análisis de alertas falsas en un modelo de pronóstico de fallos de un modelo estocástico DES con el fin de evaluar el desempeño del modelo propuesto.

Por otra parte se encuentra el caso de estudio en [36], el modelo DES en el estudio representa la gestión en camas UCI en un departamento de emergencias. El desempeño del modelo y la capacidad predictiva se evalúa por medio de la tasa de falsos positivos, verdaderos positivos, sensibilidad, especificidad y la curva Receiver Operating Characteristic (ROC). La curva ROC es una representación gráfica que compara la sensibilidad y especificidad, esta grafica sensibilidad en función de 1-especificidad.

3 Diseño de Metodológico

Como se mencionó en la introducción, el objetivo de la presente investigación es la comparación de dos métodos de detección de fallos en sistemas de eventos discretos estocásticos.

Las etapas para desarrollo metodológico de la investigación son:

1. Selección de los métodos objeto de estudio
2. Programación de los algoritmos propuestos en cada método
3. Validación de los algoritmos
4. Diseño experimental

3.1 Selección de los métodos de detección y aislamiento de fallos a comparar

En la Tabla 2 se consolida la información encontrada en la revisión de la literatura descrita en el capítulo 2. En el cuadro se clasifica a cada estudio de la siguiente manera: Alcance del método: FDI detección y aislamiento del fallo; FD detección del fallo; FI detección, aislamiento e identificación del fallo. Técnica usada. Formalismos de representación: PN, TPN, IPN, TIPN, stIPN, SPN o TA. Características de tiempo: pdf, función de densidad de probabilidad; Rango probabilístico. Disponibilidad del algoritmo y Técnica para generación de eventos: señales de E/S del sistema, modelo supervisado por un experto o uso de eventos reactivos.

Tabla 2. Comparación de estudios

Estudio	Alcance del método	Técnica	Formalismo de representación	Características de tiempo	Disponibilidad del algoritmo	Generación de eventos
Schneider, Litz, & Lesage, 2012 [5]	FD	Min / Max Distribución normal y con sesgo	TA	pdf	✓	E/S del sistema
Zemouri & Faure, 2006 [11]	FDI	Comparación	TA	pdf	✓	-
Rachidi, Leclercq, Pigne, & Lefebvre, 2018 [14]	FDI	Media móvil Limites	PN	Rango probabilístico	✓	-
Lefebvre & Leclercq, 2011 [16]	FDI	Residuales Limites	TPN	pdf	✓	-
Lefebvre & Leclercq, 2020 [18]	FDI	Residuales Diag+, diag- probabilidad	TPN	pdf	✓	-
D. M. Muñoz, A. Correcher, E. García, and F. Morant, 2015 [37]	FDI	-	St-IPN	Rango probabilístico	✓	E/S del sistema
Schneider, Litz, & Danancher, 2011 [27]	FDI	Comparación con model knowledge	TA	pdf	✓	E/S del sistema
Lefebvre, Rachidi, Leclercq, & Pigne, 2018 [32]	FDI	Probabilidad	TPN	pdf	✓	-
J. W. Vásquez Capacho, C. G. Perez Zuñiga, Y. A. Muñoz Maldonado, and A. Ospino Castro [34]	FDI	Detección de eventos simultáneos	V-Nets	pdf	✓	-

Para realizar la selección de los artículos, primero se filtra de acuerdo al alcance del método y el segundo filtro por la técnica usada para el tratamiento del fallo; de tal manera que se comparen métodos que realicen detección y aislamiento de fallos temporizados a partir de técnicas diferentes.

Aplicando los filtros anteriormente mencionados con la información presentada en la Tabla 2 y como resultado del primer filtro se crean dos grupos: primer grupo se encuentran [11], [14], [27], estudios que usan la técnica comparación y el segundo grupo los estudios [16], [18], usan residuales de tiempo. El primer grupo se puede dividir en dos técnicas de comparación, siendo [14] con la técnica de media móvil representa un análisis más complejo y detallado para poder realizar el FDI. En el segundo grupo existen dos técnicas basadas en residuales siguiendo el estudio [18] aquel que trabaja TPN. Por esta razón, son estudios candidatos para plantear una comparación de dos métodos de identificación de fallos en DES temporizados estocásticos frente a la capacidad de detectar y aislar fallos bajo el formalismo de redes de Petri temporizadas estocásticas; dado que en las propuestas relacionadas no es evidente el desempeño de los métodos de diagnóstico fallos en DES temporizados frente a la localización del fallo.

3.2 Programación y validación de algoritmos

Los algoritmos se programaron en Matlab, con base en la siguiente información:

3.2.1 Algoritmo No. 1

El algoritmo está basado en el trabajo reportado en [18]. De acuerdo a la información suministrada, se diseña el diagrama de flujo presentado en la Figura 18.

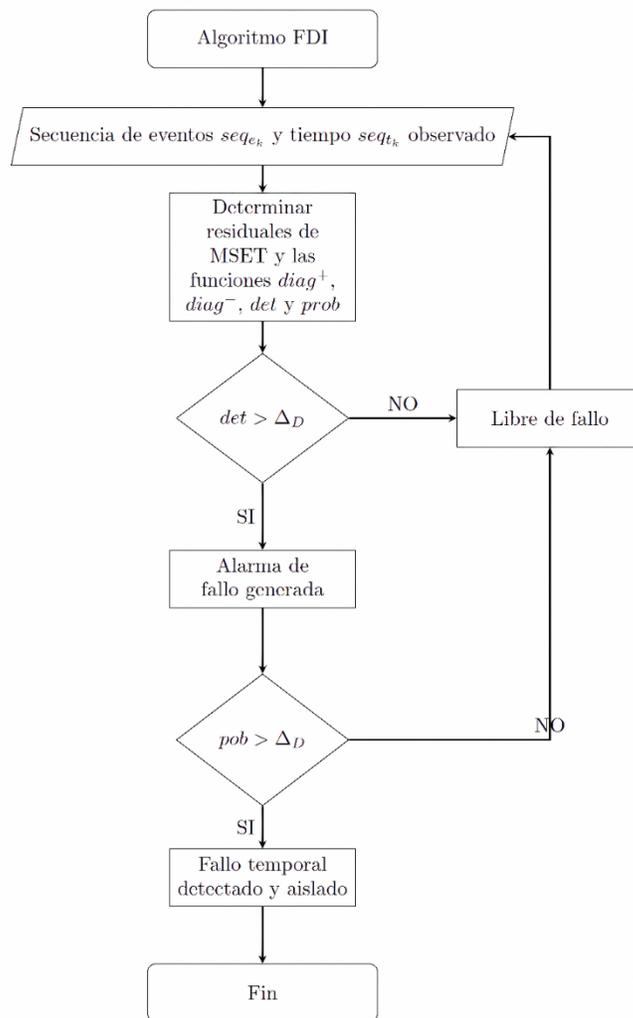


Figura 18 Diagrama de flujo de Algoritmo No. 1

Fuente: Los autores

Las entradas del algoritmo FDI son el conjunto de eventos $seq_{e_k} = (e_1 e_2 \dots e_k)$ y el conjunto de tiempos de cada evento $seq_{t_k} = (t_{e_1}, t_{e_2}, \dots, t_{e_k})$, estos conjuntos se forman a partir del conjunto de señales de entrada y salida del sistema que se modela, un ejemplo de la formación de los dos conjuntos se muestra en el capítulo 3.3.1. Con los datos de entrada se determina las trayectorias elementales de tamaño mínimo $MSET$ y las funciones $diag^+$, $diag^-$, det y $prob$. Para encontrar $MSET$ se calculan primero todas las trayectorias (similar a los T-invariantes) que se forman en la PN.

La ecuación (1) es la expresión para calcular los residuales, para este proceso se necesita MA representado por la ecuación (6), $MSET$ y el conjunto de trayectorias observadas S .

$$\delta(MA(t_{e_k}), mset, S) = MA(t_{e_k}) - t_{e_k}(mset, S) \quad (1)$$

La función $diag^+$ y $diag^-$ es el resultado de seleccionar los valores máximos y mínimos respectivamente, del conjunto de residuales.

$$diag^+ = \max\{\delta(MA(t_{e_k}), mset, S) \in MSET; S \in R_{obs}\} \quad (2)$$

La función $diag^+$ se expresa matemáticamente mediante la ecuación (2) y $diag^-$ con la ecuación (3).

$$diag^- = \min\{\delta(MA(t_{e_k}), mset, S) \in MSET; S \in R_{obs}\} \quad (3)$$

En la ecuación (6) se utiliza para el cálculo para la función det usada para evaluar los residuos máximos y encontrar un fallo temporal en el tiempo analizado. La variable T_j representa a cada una de las transiciones de la PN y q al total de las transiciones.

$$det = \frac{1}{q} \sum_{T_j \in T} diag^+(T_j) \quad (4)$$

Por último se define la función $prob$ que utiliza la función $diag^-$. Esta función se usa para calcular la probabilidad de fallo afecte al evento o transición que está siendo evaluado.

$$\begin{aligned} prob &= diag^- / N, \text{ if } (det > \Delta_D \wedge diag^+ > \Delta_D) \\ prob &= diag^- / N, \text{ de lo contrario} \end{aligned} \quad (5)$$

Donde N se denomina parámetro de normalización del tiempo, se calcula con la suma de todos los valores de la función $diag^-$ que hayan sobrepasado el umbral Δ_D .

$$N = \sum_{T_j | (det > \Delta_D \wedge diag^+ > \Delta_D)} diag^-(T_j) \quad (6)$$

- Validación del Algoritmo 1

El proceso de validación de este algoritmo se realizó con la información suministrada en el estudio y replicando los ejemplos expuestos en el mismo, como se muestran en la Figura 16 y Figura 17. El algoritmo sigue los pasos descritos en el diagrama de flujo de la Figura 18, obteniendo los resultados de la validación del algoritmo en Figura 22. En la Figura 22 se presentan tres datos: en azul la función $diag^+$, en rojo $diag^-$ y en amarillo la función $prob$. Los datos muestran el resultado de inducir un fallo temporal al evento T_2 , en donde la función $diag^+$ detecta el fallo, en la Figura 22 se puede ver que todos los resultados tienen una escala a excepción de T_2 .

Después de ingresar los valores de entrada del algoritmo se determinan los residuales del tiempo de cada evento por medio de la diferencia entre la media aritmética del tiempo con el tiempo observado de cada evento, descrito en la ecuación (7). Como se muestra en la Figura 19 en azul. El gráfico está acompañado por el umbral (en rojo) $\bar{x} \pm th * \sigma$, donde \bar{x} representa a la media aritmética, σ la desviación estándar y th es el umbral seleccionado para obtener el mejor resultado de detección.

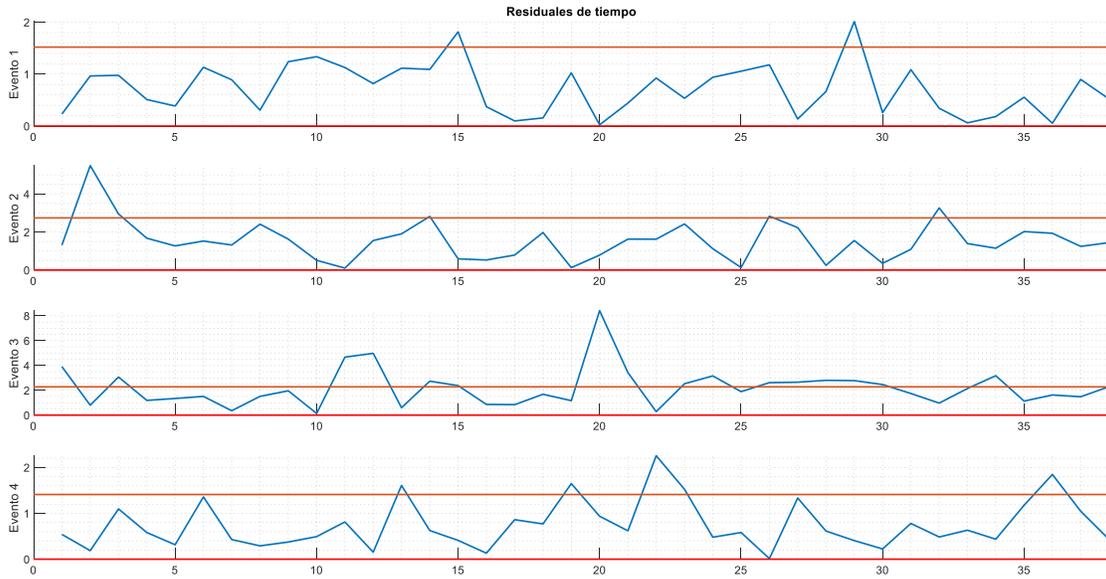


Figura 19. Residuales del tiempo

Posteriormente se calculan (ver Figura 20) las funciones $diag^+$ (azul), $diag^-$ (rojo) y la función de probabilidad (negro) para cada evento.

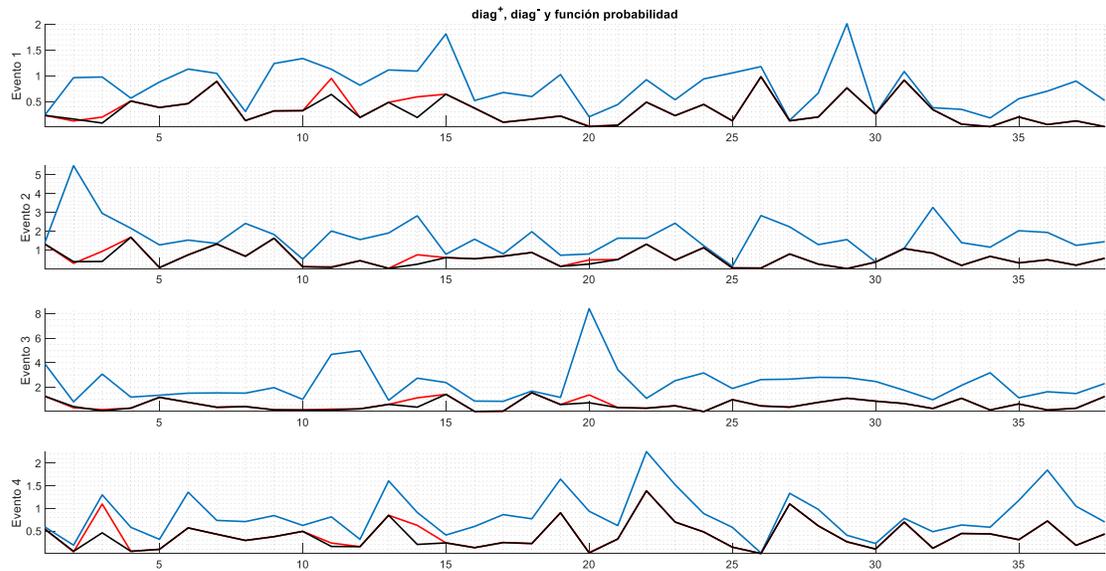


Figura 20. Función $diag^+$, $diag^-$ y función de probabilidad

En la Figura 21 se encuentran las alarmas generadas por cada evento en cada secuencia, en azul está el conjunto de eventos, en rojo están los límites definidos y en negro están las alarmas generadas por detección de fallos temporales.

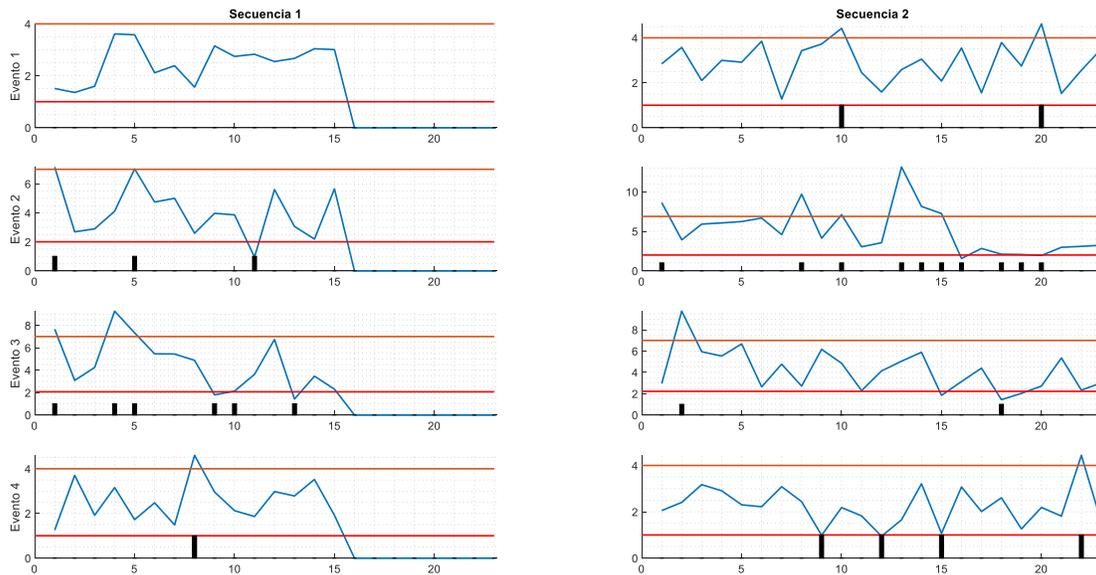


Figura 21. Alarmas de detección de fallo temporal algoritmo No.1

El proceso de validación de este algoritmo se realizó con la información suministrada en el estudio [18] y replicando los ejemplos expuestos en el mismo, como se muestran en la Figura 16 y Figura 17. El algoritmo sigue el diagrama de flujo de la Figura 18, obteniendo los resultados de la validación del algoritmo en Figura 22. En la figura se presentan tres datos: en azul la función $diag^+$, en rojo $diag^-$ y en amarillo la función $prob$. Los datos muestran el resultado de inducir un fallo temporal al evento T_2 , en donde la función $diag^+$ detecta el fallo, en la figura se puede ver que todos los resultados tienen una escala a excepción de T_2 .

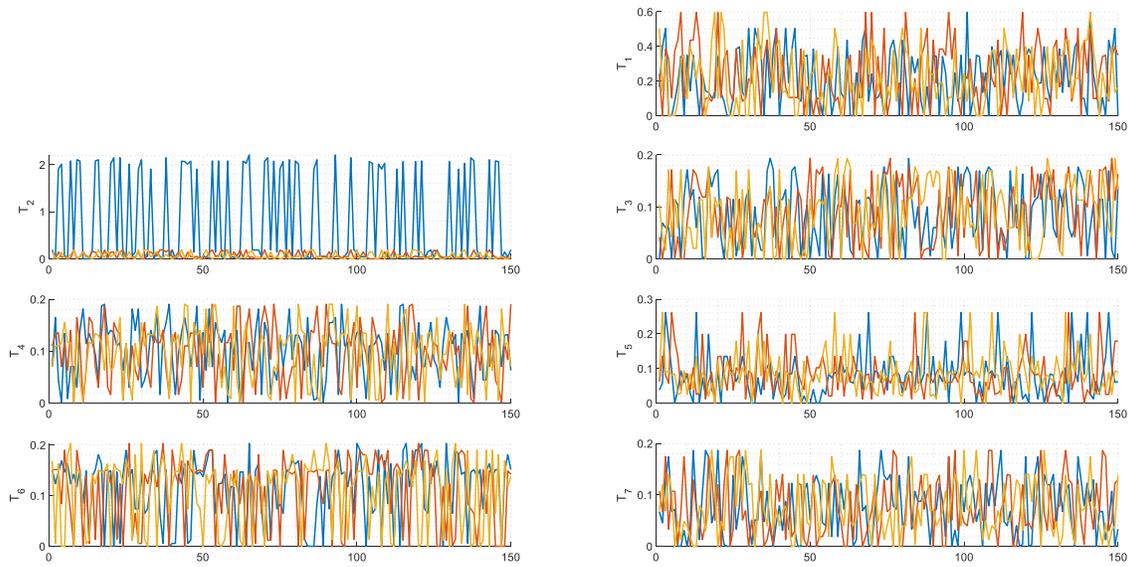


Figura 22. Validación de datos Algoritmo No. 1.

3.2.2 Algoritmo No. 2

El algoritmo está basado en el trabajo reportado en [14]. De acuerdo a la información suministrada, se diseña el diagrama de flujo presentado en la Figura 23.

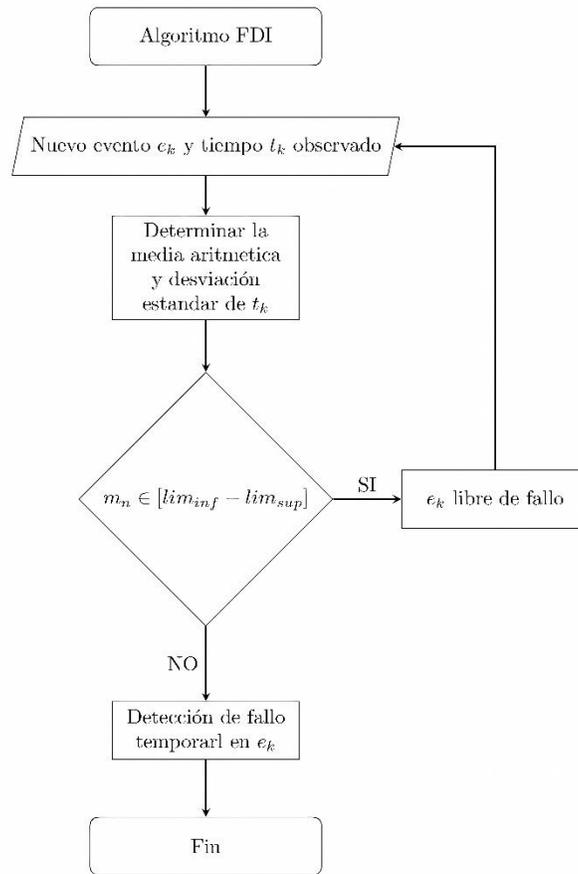


Figura 23. Diagrama de flujo de Algoritmo No 2.

Las entradas al algoritmo 2 son: $seq_{e_k} = (e_1 e_2 \dots e_k)$, el conjunto de tiempos de cada evento $seq_{t_k} = (t_{e_1}, t_{e_2}, \dots, t_{e_k})$ y el conjunto de tiempos con los fallos inducidos. Con el conjunto de tiempos se determina la media móvil (MA) con la ecuación (6), donde N representa la ventana de tiempo utilizada para determinar la media móvil.

$$m_j = m_{j-1} + \frac{t_j + t_{j-1} + \dots + t_{j-N}}{N} \quad (7)$$

Si el valor actual de m_j está entre los límites inferior y superior definidos, entonces es un evento libre de fallo y en caso contrario se detecta el fallo temporal generando una alarma en la secuencia que pertenece. El término t_j representa los tiempos de cada evento.

- Validación del Algoritmo 2

El proceso de validación de este algoritmo se realizó con la información suministrada en el estudio y replicando los ejemplos expuestos en el mismo, como se muestran en la Figura 15. El algoritmo sigue los pasos descritos en el diagrama de flujo de la Figura 23, obteniendo los resultados de la validación del algoritmo en la Figura 26.

Enseguida se definen los límites superior e inferior como la $m_c \pm 0.5\sigma_c$ donde m_c y σ_c representa la media aritmética y la desviación estándar del tiempo respectivamente, como se muestra en rojo en la Figura 15. La Figura 24 es el resultado de definir los límites, en azul se encuentra el conjunto de tiempo de los eventos con ruido y en rojo se encuentra cada una de las alarmas de detección de fallos temporales.

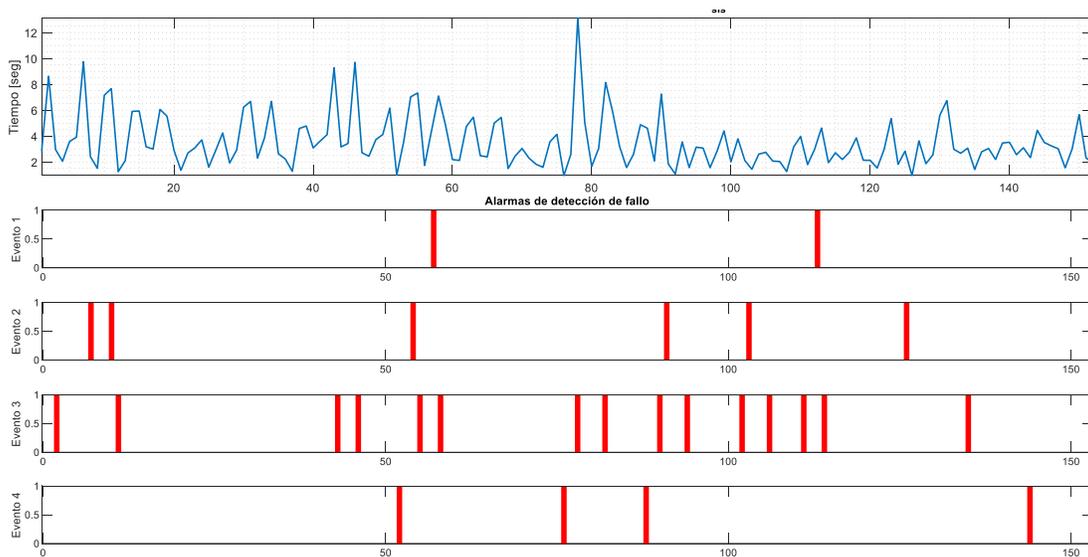


Figura 24. Alarmas de detección de fallos temporales

La Figura 25 corresponde al conjunto de tiempo separadas por cada secuencia (señal de color azul), en rojo los límites para cada evento y en negro las alarmas de detección de fallo temporal generadas en cada evento.

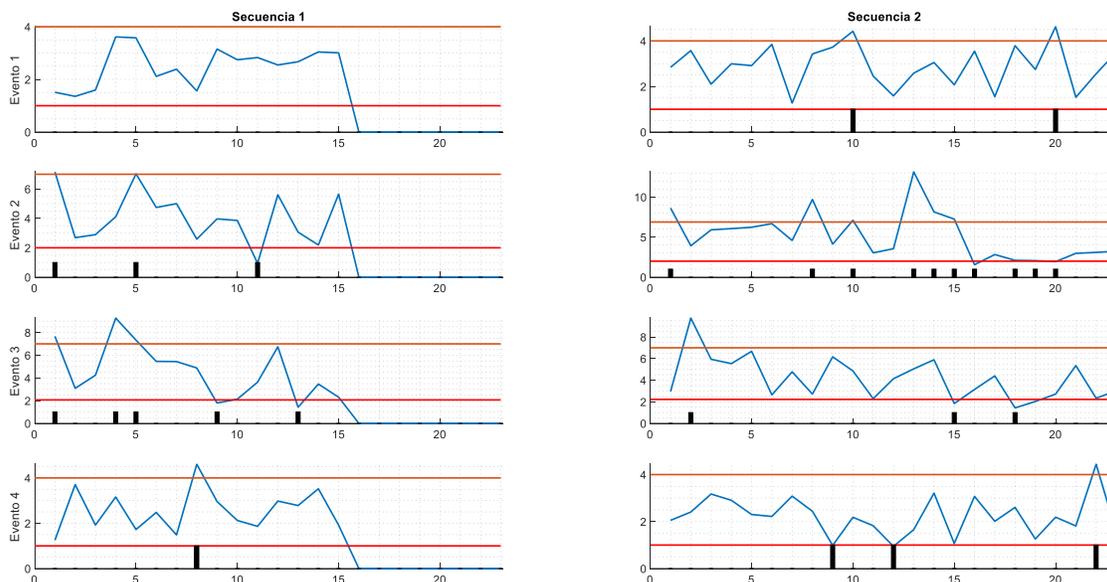


Figura 25. Alarmas de detección de fallos temporales por cada evento y secuencia

El proceso de validación sigue los pasos del algoritmo de la Figura 23. En la Figura 26 se encuentra el resultado de inducir un fallo al evento T_2 , la columna de la izquierda representa media móvil del tiempo de cada evento y la derecha los valores de desviación estándar. Se puede ver que la desviación de T_2 marca un aumento significativo desde el instante 10 en la desviación estándar, significa que identifica el comportamiento no normal del tiempo y se detecta un fallo. Como el algoritmo se ejecuta evento a evento, se puede también aislar el fallo.

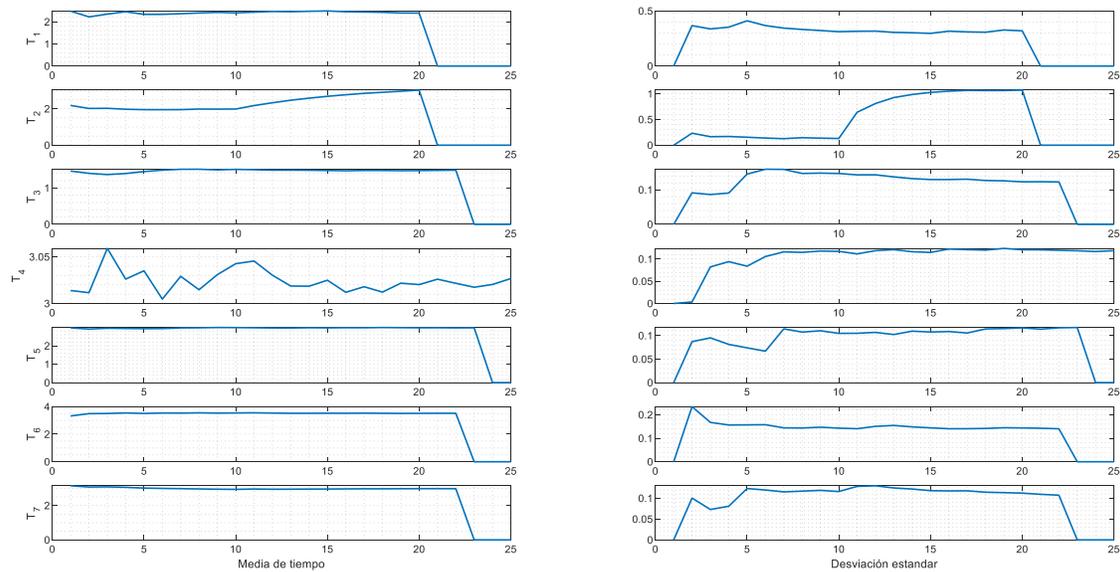


Figura 26. Validación de datos Algoritmo No. 2.

Cabe aclarar que los estudios no cuentan con datos y resultados detallados para replicar exactamente los mismos resultados, pero se evidencia con los resultados de validación del algoritmo cumplen con los pasos lógicos de los dos algoritmos y el objetivo de FDI.

3.3 Diseño de la investigación

Para comparar los algoritmos se recurre a un diseño experimental aplicado a diferentes casos de estudio.

La experimentación que se propone, se basa en simulación, cuyo objetivo es el análisis cuantitativo de cada caso de estudio que evoluciona a partir de eventos cronológicos. Es decir, la simulación debe reproducir de manera precisa las secuencias de eventos de los casos de estudio.

3.3.1 Variables del experimento

En la experimentación se controla el número de fallos inducidos en los modelos y se mide la eficiencia en la detección y aislamiento del fallo, la detección de falsas alarmas y el costo

computacional en cada uno de los algoritmos de los métodos seleccionados, para que esas medidas luego sean comparadas a partir de métricas estadísticas.

3.3.2 Proceso de experimentación

Se utilizan tres estudios de caso obtenidos del estado de arte de la investigación [14], [15], [38], estos fueron seleccionados con base en la existencia de la información suficiente para replicar los ejemplos, para realizar correctamente la programación de los algoritmos.

La experimentación se realizó de la siguiente manera para cada caso de estudio, en cada uno de los métodos seleccionados:

1. Estructura de la t-IPN: Modelar el comportamiento del caso de estudio como una t-IPN y definir los conjuntos de eventos E , lugares P , transiciones TR ; matrices $Pre: P \times TR \rightarrow Z$ y $Post: TR \times P \rightarrow Z$ y la función de etiquetado de las transiciones $\lambda: TR \rightarrow E$. δ , donde δ es la función temporizada que puede ser expresada como un intervalo de tiempo o como una función de densidad de probabilidad (*pdf*).
2. Establecimiento de las condiciones iniciales: Identificar todas las secuencias de eventos temporizados que definen el comportamiento libre de fallos que corresponda a la dinámica de la t-IPN modelada en el punto anterior.
3. Definición de los escenarios de experimentación: Un escenario está compuesto por la transición o la combinación de transiciones de la t-IPN que se manipularán en un experimento.
4. Obtención de los datos: Los datos se obtienen mediante simulación de cada uno de los escenarios en los algoritmos programados en Matlab. Los pasos son:
 - a. Simulación libre de fallos. Se generan números aleatorios dentro de los rangos de tiempo nominales de las transiciones durante más de mil ciclos de funcionamiento y se encuentran las secuencias de eventos simuladas del caso de estudio en un comportamiento normal. Con este proceso se obtiene la información temporizada del modelo libre de fallos.

La cantidad de iteraciones generadas depende de la cantidad de eventos y las secuencias que tiene cada caso de estudio.

- b. Simulación en modo de fallo: Para simular un fallo, se introduce inicialmente un nivel de ruido del 10% al tiempo nominal de la transición o transiciones que se desea manipular en el escenario *i*. El resultado de este proceso es el conjunto de tiempos con fallo.
 - c. Detección de fallos: el conjunto de eventos y tiempo con fallos inducidos son los datos de entrada para los algoritmos 1 y 2 y con base en ellos se realiza el proceso de detección de fallos.
 - d. Se repiten los pasos del **b** al **c**, aumentando del nivel de ruido en un $\pm 10\%$, hasta que se alcance un nivel de ruido del $\pm 100\%$.
 - e. Se repiten los pasos del **b** al **d** para todos los escenarios propuestos.
5. Cálculo de las medidas de desempeño:
- a. Tiempo de ejecución: es el tiempo que tarda cada algoritmo en realizar el proceso de FDI para un conjunto de eventos y tiempos.
 - b. Clasificación de los eventos de fallos detectados y aislados por cada algoritmo como: Fallos inducidos y aislados (verdaderos positivos), eventos que no son fallo y que son aislados de esta manera (verdaderos negativos), eventos que no son fallo y aislado de esta manera (falsos positivos), fallos inducidos y que no son aislados (falso negativo).
6. Evaluación de las medidas de desempeño: Para comparar los dos algoritmos de detección se utilizan cuatro parámetros, la sensibilidad y especificidad para determinar el porcentaje de eventos de fallos y eventos libres de fallos clasificados correctamente, análisis de la varianza, y por último el tiempo de ejecución que tarda cada algoritmo en realizar la detección.
- a. Sensibilidad: es un indicador probabilístico realizado en pruebas diagnósticas, representa la probabilidad que un experimento estime correctamente el resultado, en el caso de diagnóstico, es la capacidad que se

tiene para detectar correctamente un fallo existente. Si la sensibilidad aumenta, la tasa de falsos negativos disminuye y por ende menor error en el proceso de detección del n -porcentaje de casos positivos detectados como positivos. En la ecuación (6), vp representa los verdaderos positivos, es decir los eventos clasificados correctamente como fallo y fn los falsos negativos, que representa los eventos de fallo que no fueron clasificados como fallos [39].

$$Sensibilidad = \frac{vp}{vp + fn} \quad (8)$$

- b. Especificidad: La especificidad es un indicador probabilístico realizado en pruebas diagnósticas, que representa la probabilidad de un experimento en desestimar correctamente un resultado, es decir que, en un contexto de detección de fallos, el método clasifica correctamente a los eventos que estén libres de fallos. Si la especificidad aumenta, la tasa de falsos positivos disminuye y esto implica la capacidad de distinguir correctamente entre fallos reales y condiciones normales del sistema. Otro punto de vista que representa a la especificidad es, el n -porcentaje de casos negativos detectados como negativos. En la ecuación (9), vn significa los verdaderos negativos, es decir los eventos clasificados correctamente como libres de fallo y fp los falsos positivos que representa los eventos clasificados incorrectamente como eventos de fallo [39].

$$Especificidad = \frac{vn}{vn + fp} \quad (9)$$

- c. Análisis de la varianza: se utiliza la función del software Matlab llamada *anova1*, usada para analizar si existe una diferencia estadísticamente significativa entre los valores de sensibilidad y especificidad.

4 Presentación de resultados

A continuación, se presentan los casos de estudios con el proceso de generación de datos que se usan para evaluar a los dos algoritmos.

4.1 Caso de estudio No. 1

El primer caso de estudio se relaciona con un sistema de envío de mensaje [15]. Consiste en mensajes transmitidos del cliente A al cliente B (ver Figura 27a). Primero, un separador divide el mensaje en dos paquetes para enviar a través de dos canales separados. A través del primer canal, el paquete 1 es conducido por el enrutador R1, antes de ingresar al búfer 1. El paquete 2 es procesado por el enrutador R2 y entra al buffer 2. Finalmente, los paquetes se recopilan para reconstituir el mensaje original y se envía un acuse de recibo al remitente. Las operaciones de división y ensamblaje son operaciones rápidas en comparación con las operaciones del enrutador y se comportan de acuerdo con duraciones estocásticas de funciones de densidad (pdfs) triangulares simétricas. Los enrutadores son idénticos y se comportan con duraciones estocásticas de pdfs triangulares simétricas.

El modelo en una t-IPN del caso de estudio Nro 1 se muestra en la Figura 27 (b).

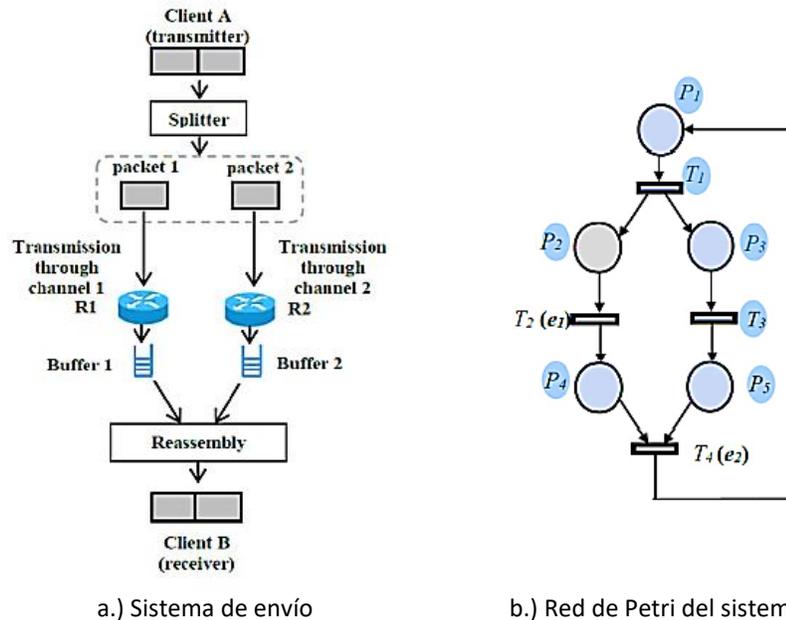


Figura 27. Caso de estudio No. 1. Tomado de [15]

La t-IPN que representa el comportamiento inicial y libre de fallos para el caso de estudio 1, se define así. P_1 representa el envío de un mensaje desde el cliente A, P_2 el paquete 1 del mensaje se procesa en el enrutador 1, P_3 el paquete 2 del mensaje se procesa en el enrutador 2, P_4 paquete 1 del mensaje está en el buffer 1 y P_5 el paquete 2 del mensaje está en el buffer 2. Los eventos son $E = \{e_1, e_2, e_3, e_4\}$; donde e_1 es la división del mensaje en dos paquetes, e_2 enviar el paquete 1 del mensaje al buffer 1, e_3 enviar el paquete 2 del mensaje al buffer 2 y e_4 reconstrucción del mensaje para entregar al cliente B. Las funciones de asignación son $\lambda(T_1) = e_1T(1,4,2.5)$, $\lambda(T_2) = e_2T(2,7,4.5)$, $\lambda(T_3) = e_3T(2,7,4.5)$ y $\lambda(T_4) = e_4T(1,4,2.5)$.

Existen dos tipos de secuencias generadas: $sec_1 = (e_1e_2e_3e_4)$ y $sec_2 = (e_1e_3e_2e_4)$, las dos tienen la misma probabilidad de ser ejecutadas, como se puede ver en la información completa reportada en el Anexo 1

A partir del comportamiento inicial se realiza la simulación libre de fallos. Para ello se ejecutan 5700 ciclos, en donde en cada ciclo se genera una secuencia de eventos de la t-IPN de manera aleatoria, considerando el comportamiento estocástico de cada transición. Una sección de los eventos generados, en este caso de estudio, se presentan en la Figura 28, donde se puede ver el tiempo de duración de cada evento y las dos secuencias que se generan en este estudio sin fallo. El tiempo de duración de cada evento es aleatorio y corresponde a las funciones de densidad de las distribuciones de cada transición.

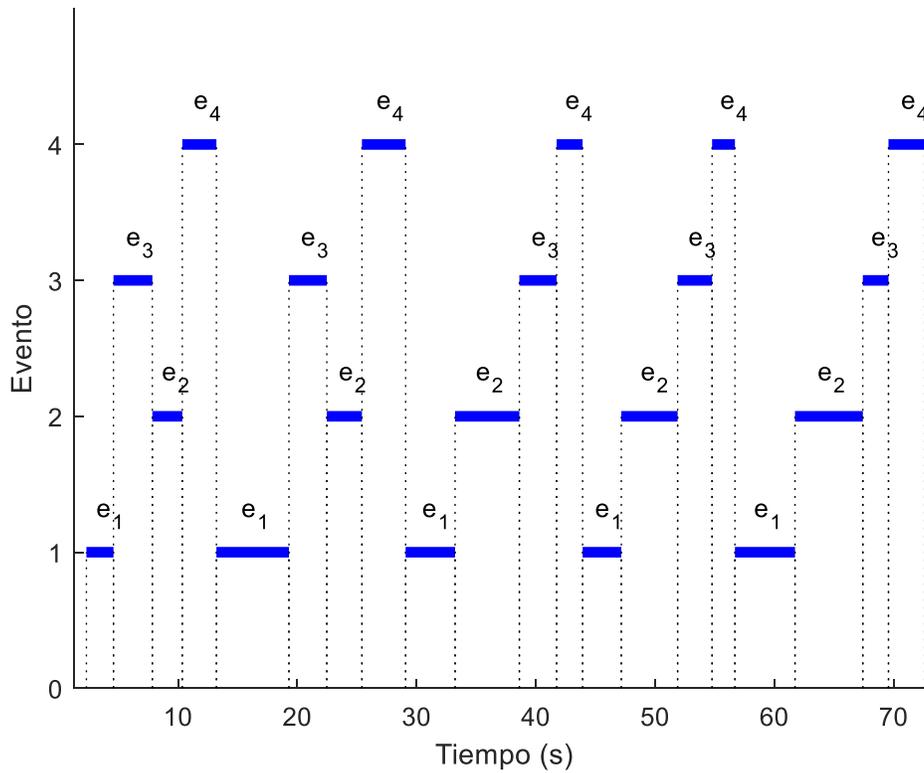


Figura 28. Generación de eventos. Caso de estudio No. 1

Una vez se obtiene la información temporizada del modelo libre de fallos, se inicia el proceso de experimentación. Para ello se definen los escenarios de experimentación:

Tabla 3. Escenarios de experimentación para el caso de estudio Nro 1

Experimento	Transiciones manipuladas	Intensidad del fallo (\pm)
1	$\{t_1\}$	10%, 20%, 30%, 40%, 50%, 60%, 70%, 80%, 90% y 100%.
2	$\{t_2\}$	
3	$\{t_3\}$	
4	$\{t_4\}$	
5	$\{t_1, t_2\}$	
6	$\{t_1, t_3\}$	
7	$\{t_1, t_4\}$	
8	$\{t_2, t_3\}$	
9	$\{t_2, t_4\}$	

Experimento	Transiciones manipuladas	Intensidad del fallo (\pm)
10	$\{t_3, t_4\}$	
11	$\{t_1, t_2, t_3\}$	
12	$\{t_1, t_2, t_4\}$	
13	$\{t_1, t_3, t_4\}$	
14	$\{t_2, t_3, t_4\}$	
15	$\{t_1, t_2, t_3, t_4\}$	

A continuación, se presentan los resultados del experimento 1. Con base en los comportamientos estocásticos descritos anteriormente, se introduce un nivel de ruido del 10% al 100% en la transición t_1 involucrada en el experimento, mostrado en la Tabla 3. Los resultados de la simulación se ven en la Figura 29. En azul los resultados de tiempo, en negro el tiempo con los fallos inducidos y en rojo se encuentran los fallos inducidos en una ventana de tiempo de 1500 muestras.

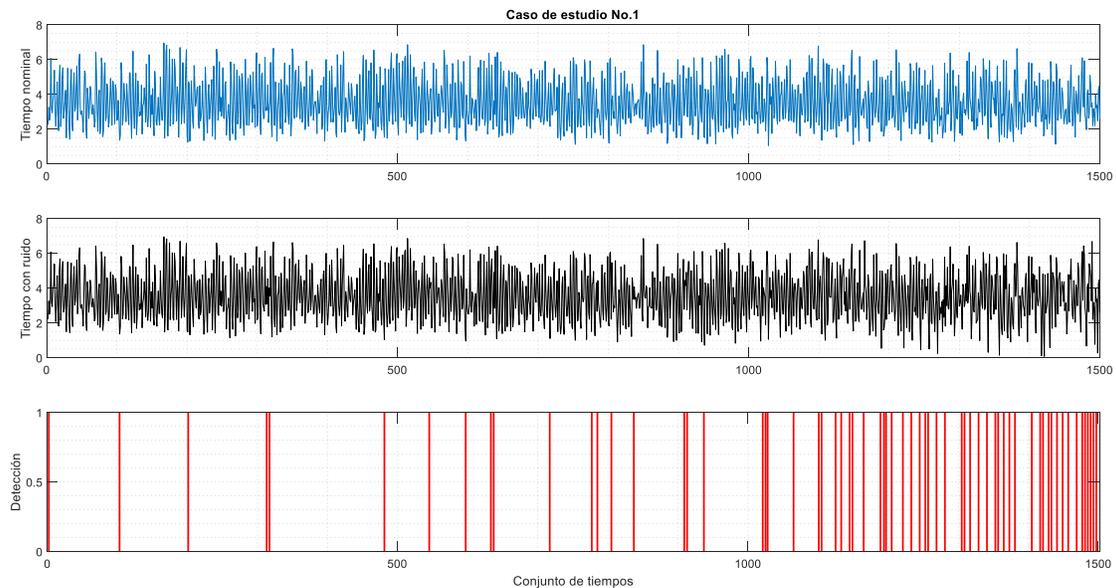


Figura 29. Simulación caso de estudio No. 1

Al aplicar un fallo con diferentes niveles de intensidad en las transiciones t_1 , t_2 y t_3 , es decir el experimento 11, en la Figura 30 se presentan los resultados, con los tiempos de todos los eventos (color azul) y con las alarmas que se generan (color rojo).

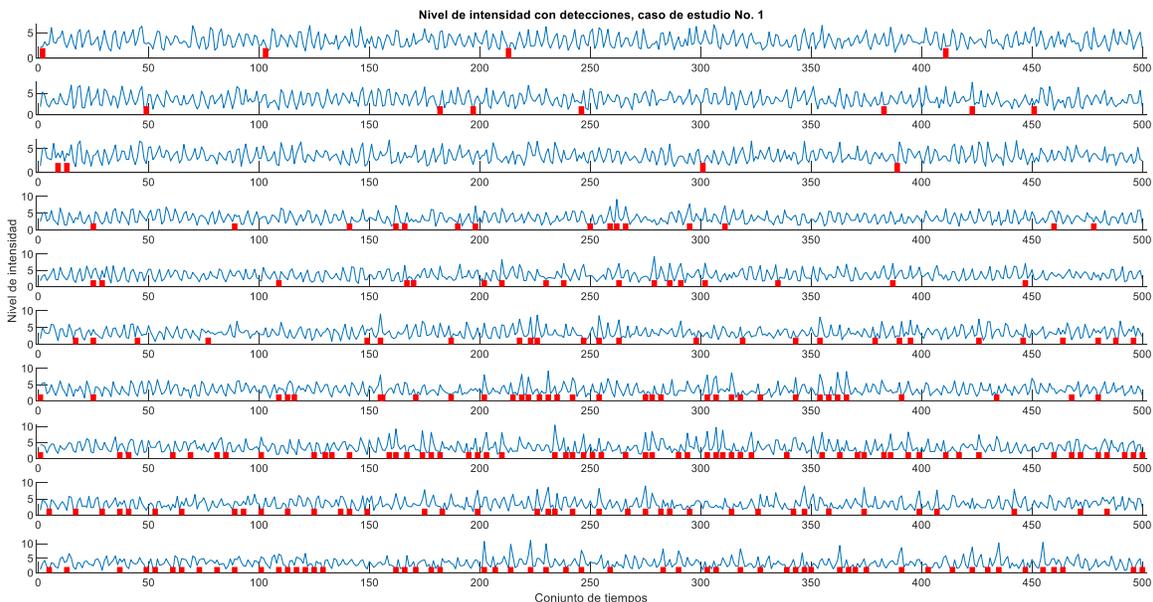


Figura 30. Fallos con diferentes niveles de intensidad. a) Nivel 10%, b) 20%, c) 30%, d) 40%, e) 50%, f) 60%, g) 70%, h) 80%, i) 90% y j) 100%.

En la Figura 30, se puede observar que a medida que aumenta la intensidad del ruido aumenta la cantidad de fallos inducido, que es el propósito del experimento. Las medidas de desempeño de este experimento se muestran en la Tabla 4.

Tabla 4. Medidas de desempeño de todos los experimentos en el caso de estudio Nro 1

Medida de desempeño	Unidad de medida	Medición			
		Algoritmo 1		Algoritmo 2	
		Sec 1	Sec 2	Sec 1	Sec 2
Tiempo de ejecución	Segundos	0,0803	0,0276	0,1488	0,0937
Fallos inducidos	Número	1132	1050	1132	1050
Fallos inducidos y aislados (verdaderos positivos).	Número	647	587	1037	958
Eventos que no son fallo y que son aislados de esta	Número	10308	10262	10199	10134

Medida de desempeño	Unidad de medida	Medición			
		Algoritmo 1		Algoritmo 2	
		Sec 1	Sec 2	Sec 1	Sec 2
manera (verdaderos negativos).					
Eventos que no son fallo y aislado de esta manera (falsos positivos).	Número	20	28	129	156
Fallos inducidos y que no son aislados (falso negativo).	Número	485	463	95	92

La evaluación de los promedios de las medidas de desempeño de todos los experimentos en el caso de estudio No 1, se muestran en la Tabla 5.

Tabla 5. Evaluación de las medidas de desempeño de todos los experimentos en el caso de estudio No 1

Medida de desempeño	Algoritmo 1	Algoritmo 2
Sensibilidad	44.03%	90.97%
Especificidad	99.75%	98.54%

4.2 Caso de estudio No. 2

La planta simulada [38] de la Figura 31 está controlada por un PLC simulado con Factory E/S, está interconectada a través de TCP/IP con SIMATIC S7 de Siemens. De esta manera se emula el sistema industrial de circuito cerrado. El sistema permite mover y transferir cajas que se generan aleatoriamente en el transportador central en la parte inferior; pueden ser de dos alturas diferentes, baja o alta.

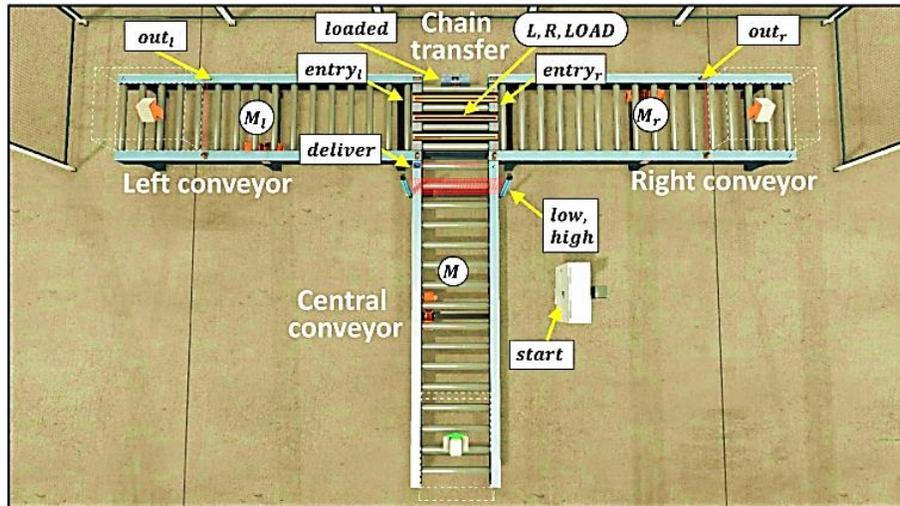


Figura 31. Planta caso de estudio No. 2. Tomada de [38]

En la Figura 32 se encuentra el modelo t-IPN que representa a la planta de la Figura 31.

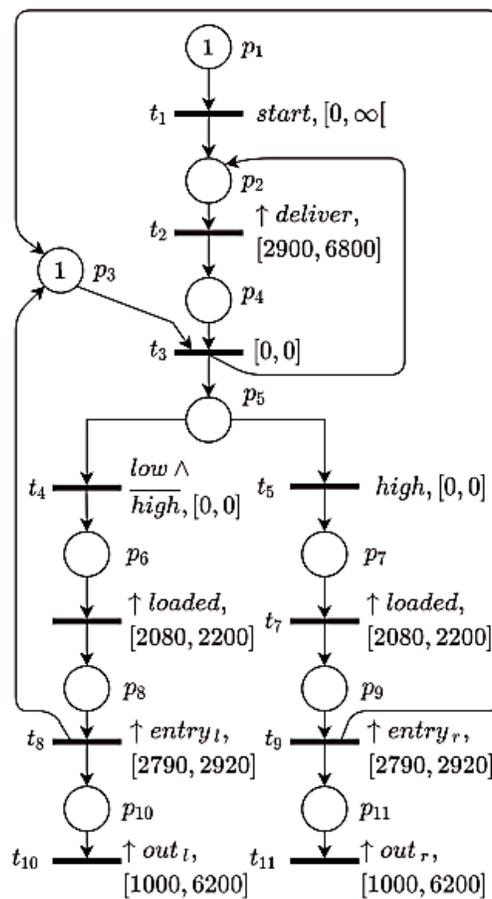


Figura 32. Modelo TPN del caso de estudio No. 2. Tomado de [38]

La t-IPN que representa el comportamiento inicial y libre de fallos para el caso de estudio 2, se define así. P_1 representa el estado de inicio del proceso, P_2 motor M activado, P_3 no hay caja en bandas secundarias, P_4 caja al final de banda central, P_5 midiendo altura de caja, P_6 y P_7 cargando caja, P_8 y P_9 fin de llenado caja, P_{10} motor M_1 de banda izquierda activado, P_{11} motor M_2 de banda derecha activado. Los eventos son $E = \{e_1, e_2, e_3, e_4, e_5, e_6, e_7, e_8, e_9\}$; donde e_1 representa el botón de *start*, e_2 detección de caja al final de la banda central, e_3 presencia de caja en zona de medir altura, e_4 sensor mide altura 1 para la caja, e_5 sensor mide altura 2 para la caja, e_6 y e_7 llenar caja, e_8 y e_9 mover. Las funciones de asignación son $\lambda(T_2) = e_2T(2.9,6.8)$, $\lambda(T_3) = e_3T(1)$, $\lambda(T_4) = e_4T(1)$, $\lambda(T_5) = e_5T(1)$, $\lambda(T_6) = e_6T(2.08,2.2)$, $\lambda(T_7) = e_7T(2.08,2.2)$, $\lambda(T_8) = e_8T(2.79, 2.92)$ y $\lambda(T_9) = e_9T(2.79, 2.92)$.

El modelo de la Figura 32 tiene 5 secuencias compuestas de la siguiente manera: $sec_1 = (e_2e_3)$, $sec_2 = (e_1e_2e_3e_4e_6e_8)$, $sec_3 = (e_1e_2e_3e_5e_7e_9)$, $sec_4 = (e_3e_4e_6e_8)$ y $sec_5 = (e_3e_5e_7e_9)$. De las anteriores secuencias siempre ocurre la secuencia 1, pero las secuencias 2 y 3 solo podrá ocurrir una vez ya que no son cíclicas, pero las secuencias 4 y 5 ocurre frecuentemente como se puede ver la información completa en el Anexo 2.

A partir del comportamiento inicial se realiza la simulación libre de fallos. Para ello se ejecutan 5607 ciclos, en donde en cada ciclo se genera una secuencia de eventos de la t-IPN de manera aleatoria, considerando el comportamiento estocástico de cada transición. Una sección de los eventos generados, en este caso de estudio, se presentan en la Figura 33, donde se puede ver el tiempo de duración de cada evento y las dos secuencias que se generan en este estudio sin fallo. El tiempo de duración de cada evento es aleatorio y corresponde a las funciones de densidad de las distribuciones de cada transición.

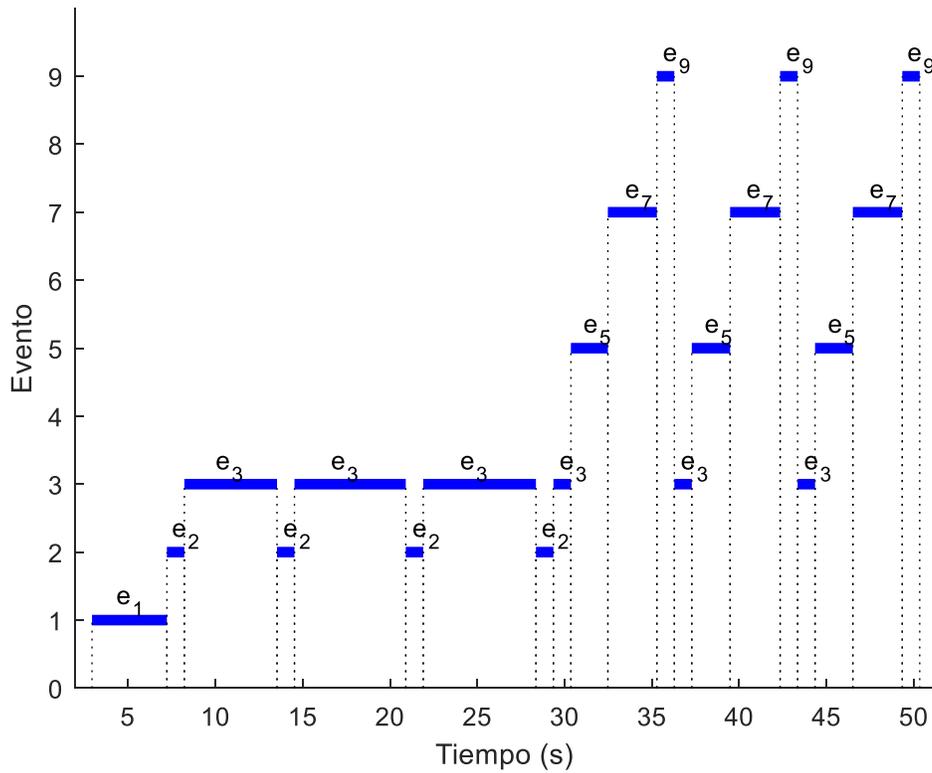


Figura 33. Generación de eventos. Caso de estudio No. 2

Una vez se obtiene la información temporizada del modelo libre de fallos, se inicia el proceso de experimentación. Para ello se definen los escenarios de experimentación:

Tabla 6. Escenarios de experimentación para el caso de estudio Nro2

Experimento	Transiciones manipuladas	Intensidad del fallo (\pm)
1	$\{t_2\}$	10%, 20%, 30%, 40%, 50%, 60%, 70%, 80%, 90% y 100%.
2	$\{t_3\}$	
3	$\{t_4\}$	
4	$\{t_5\}$	
5	$\{t_9\}$	
6	$\{t_4, t_7\}$	
7	$\{t_1, t_2\}$	
8	$\{t_4, t_5\}$	
9	$\{t_5, t_7, t_9\}$	

Experimento	Transiciones manipuladas	Intensidad del fallo (\pm)
10	$\{t_5, t_6, t_8\}$	
11	$\{t_1, t_2, t_3\}$	
12	$\{t_7, t_8, t_9\}$	
13	$\{t_2, t_3, t_5, t_7\}$	
14	$\{t_2, t_4, t_6, t_8\}$	
15	$\{t_1, t_2, t_3, t_4, t_5, t_6, t_7, t_8, t_9\}$	

A continuación, se presentan los resultados del experimento 1. Con base en los comportamientos estocásticos descritos anteriormente, se introduce un nivel de ruido del 10% al 100% en la transición t_2 involucrada en el experimento, mostrado en la Tabla 6. Los resultados de la simulación se ven en la Figura 34. En azul los resultados de tiempo, en negro el tiempo con los fallos inducidos y en rojo se encuentran las alarmas de detección generadas en una ventana de tiempo de 1500 muestras.

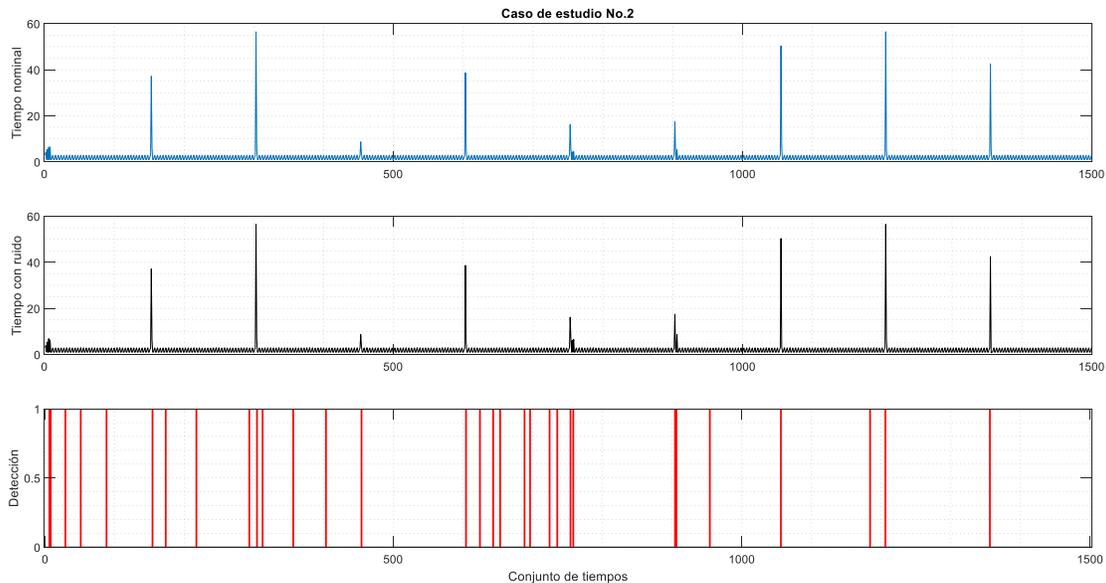


Figura 34. Simulación caso de estudio No. 2

Al aplicar un fallo con diferentes niveles de intensidad en las transiciones t_1 , t_2 y t_3 , es decir el experimento 11, en la Figura 35 se muestran los resultados, con los tiempos de todos los eventos (color azul) y con las alarmas que se generan (color rojo).

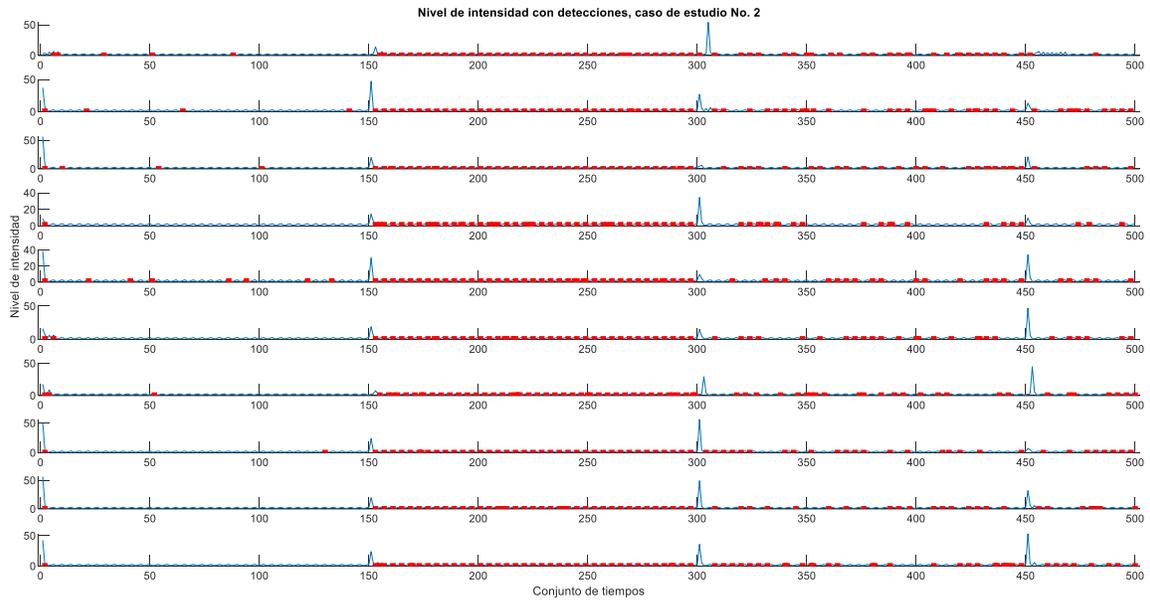


Figura 35. Fallos con diferentes niveles de intensidad. a) Nivel 10%, b) 20%, c) 30%, d) 40%, e) 50%, f) 60%, g) 70%, h) 80%, i) 90% y j) 100%

Las anteriores gráficas, Figura 35, aumenta la cantidad de fallos inducidos a medida que aumenta la intensidad de ruido.

Las medidas de desempeño de este experimento se muestran en la Tabla 7

Tabla 7. Medidas de desempeño de todos los experimentos en el caso de estudio Nro 2

Medida de desempeño	Unidad de medida	Medición									
		Algoritmo 1					Algoritmo 2				
		Sec 1	Sec 2	Sec 3	Sec 4	Sec 5	Sec 1	Sec 2	Sec 3	Sec 4	Sec 5
Tiempo de ejecución	Segundos	0,1061	0,0107	0,0202	0,0256	0,0156	0,0426	0,0464	0,0509	0,0913	0,0569
Fallos inducidos	Número	50	93	121	3330	2720	50	93	121	3330	2720
Fallos inducidos y aislados (verdaderos positivos)	Número	46	93	115	3251	2657	47	93	116	3323	2715

Medida de desempeño	Unidad de medida	Medición									
		Algoritmo 1					Algoritmo 2				
		Sec 1	Sec 2	Sec 3	Sec 4	Sec 5	Sec 1	Sec 2	Sec 3	Sec 4	Sec 5
Eventos que no son fallo y que son aislados de esta manera (verdaderos negativos).	Número	177	249	358	8540	6858	189	260	384	8401	6745
Eventos que no son fallo y aislado de esta manera (falsos positivos).	Número	14	13	31	10	12	2	2	5	149	125
Fallos inducidos y que no son aislados (falso negativo).	Número	4	0	6	79	63	3	0	5	7	5

El promedio de las medidas de desempeño de todos los experimentos en el caso de estudio Nro 2, se muestran en la Tabla 8.

Tabla 8. Evaluación de las medidas de desempeño de todos los experimentos en el caso de estudio Nro 2

Medida de desempeño	Algoritmo 1	Algoritmo 2
Sensibilidad	96.04%	98.64%
Especificidad	97.29%	97.76%

4.3 Caso de estudio No. 3

En el estudio realizado por [14], se presenta la t-IPN con los siguientes límites superior e inferior para una pdf uniforme, los eventos son $E = \{e_1, e_2, e_3, e_4, e_5, e_6, e_7\}$ y la asignación de cada transición es $\lambda(T_1) = e_1T(1, 3)$, $\lambda(T_2) = e_2T(2, 4)$, $\lambda(T_3) = e_3T(0, 3)$, $\lambda(T_4) = e_4T(2, 4)$, $\lambda(T_5) = e_5(2, 4)$, $\lambda(T_6) = e_6T(3, 4)$ y $\lambda(T_7) = e_7T(1, 5)$.

Existen cuatro tipos de secuencias generadas: $sec_1 = (e_1e_2e_5)$, $sec_2 = \{e_1e_2e_3e_6e_7\}$, $sec_3 = \{e_4e_5\}$, $sec_4 = \{e_4e_3e_6e_7\}$. Las secuencias tienen la misma probabilidad de ocurrir y todas las secuencias son cíclicas como se puede ver la información completa en el Anexo 3.

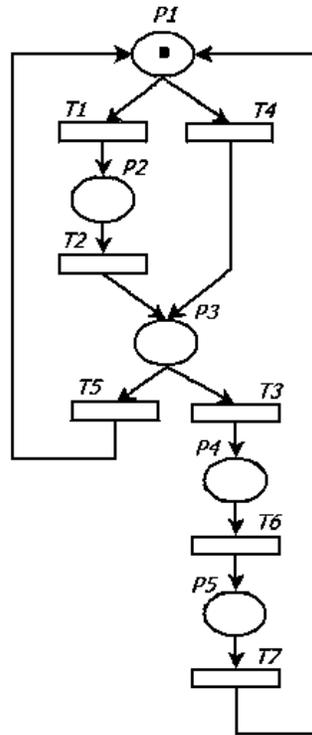


Figura 36. Modelo TPN del caso de estudio No. 3. Tomado de [14]

A partir del comportamiento inicial se realiza la simulación libre de fallos. Para ello se ejecutan 6059, en donde en cada ciclo se genera una secuencia de eventos de la TPN de manera aleatoria, considerando el comportamiento estocástico de cada transición. Una sección de los eventos generados, en este caso de estudio, se presentan en la Figura 37, donde se puede ver el tiempo de duración de cada evento y las cuatro secuencias que se generan en este estudio sin fallo. El tiempo de duración de cada evento es aleatorio y corresponde a las funciones de densidad de las distribuciones de cada transición.

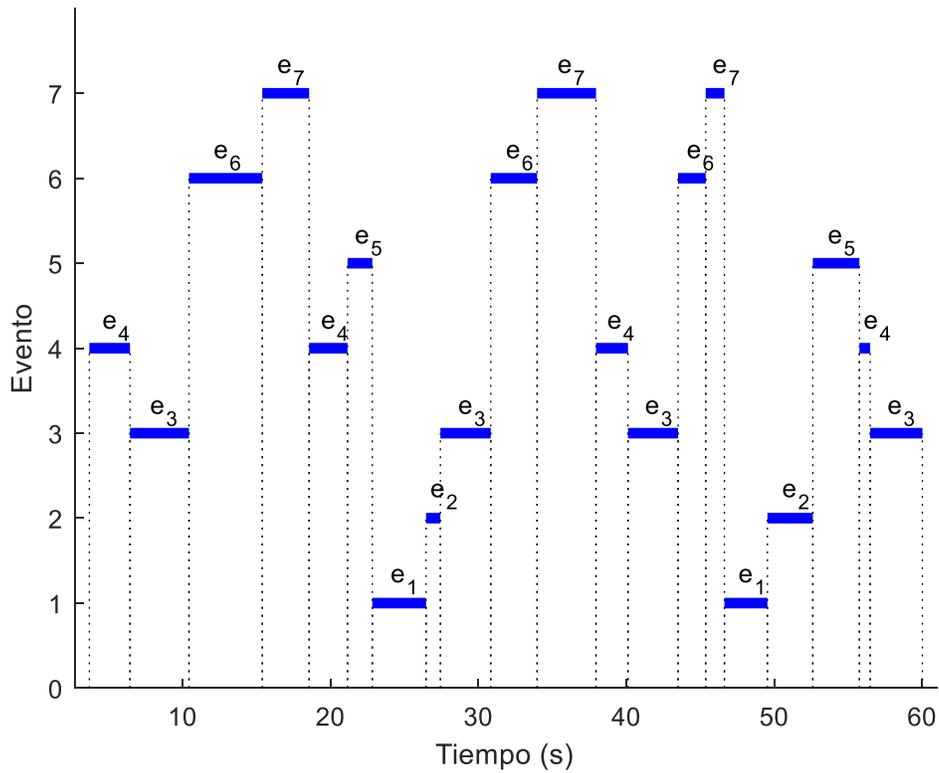


Figura 37. Generación de eventos. Caso de estudio No. 3

Una vez se obtiene la información temporizada del modelo libre de fallos, se inicia el proceso de experimentación. Para ello se definen los escenarios de experimentación:

Tabla 9. Escenarios de experimentación para el caso de estudio Nro 3

Experimento	Transiciones manipuladas	Intensidad del fallo (\pm)
1	$\{t_1\}$	10%, 20%, 30%, 40%, 50%, 60%, 70%, 80%, 90% y 100%.
2	$\{t_2\}$	
3	$\{t_4\}$	
4	$\{t_5\}$	
5	$\{t_6\}$	
6	$\{t_1, t_4\}$	
7	$\{t_1, t_2\}$	
8	$\{t_5, t_6\}$	
9	$\{t_1, t_2, t_3\}$	

Experimento	Transiciones manipuladas	Intensidad del fallo (\pm)
10	$\{t_4, t_5, t_6\}$	
11	$\{t_5, t_6, t_7\}$	
12	$\{t_4, t_5, t_6, t_7\}$	
13	$\{t_3, t_4, t_5, t_6, t_7\}$	
14	$\{t_1, t_2, t_3, t_4, t_5, t_6, t_7\}$	

A continuación, se presentan los resultados del experimento 3. Con base en los comportamientos estocásticos descritos anteriormente, se introduce un nivel de ruido del $\pm 10\%$ al $\pm 100\%$ en las transiciones t_4 involucradas en el experimento, mostrado en la Tabla 9. Los resultados de la simulación se ven en la Figura 38. En azul los resultados de tiempo, en negro el tiempo con los fallos inducidos y en rojo se encuentran las alarmas de detección generadas en una ventana de tiempo de 1500 muestras.

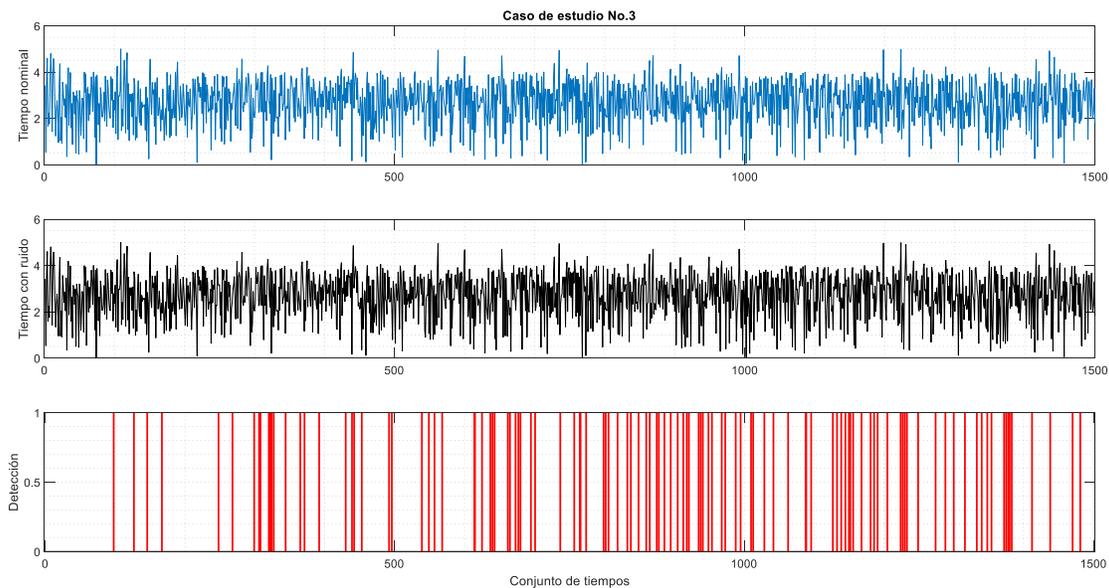


Figura 38. Simulación caso de estudio No. 3

Al aplicar un fallo con diferentes niveles de intensidad en las transiciones t_1 , t_2 y t_3 , es decir el experimento 9, en la Figura 39 se presentan los resultados, con los tiempos de todos los eventos (color azul) y con las alarmas que se generan (color rojo).

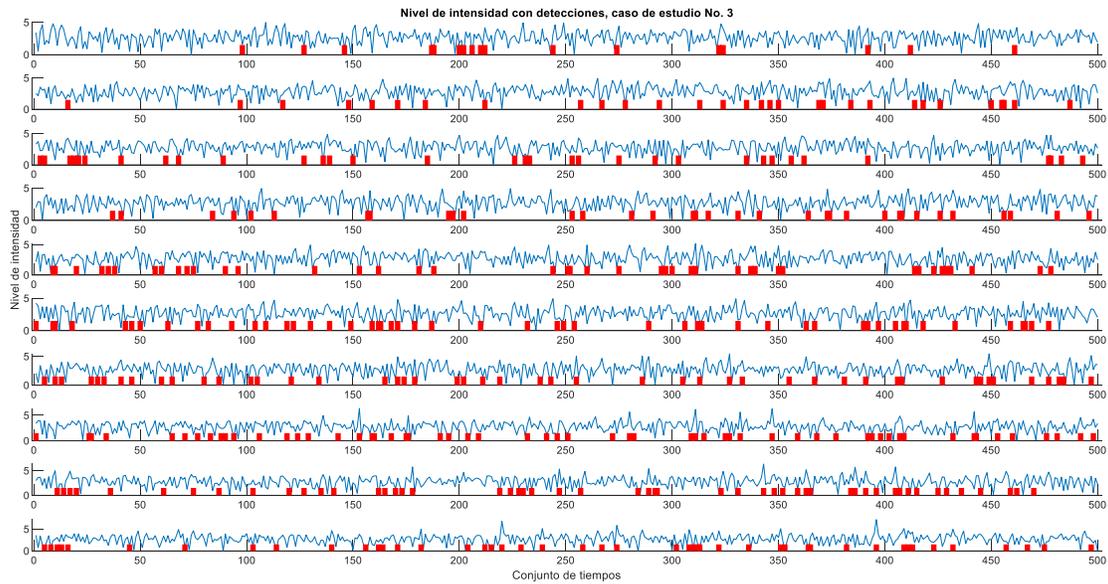


Figura 39. Fallos con diferentes niveles de intensidad. a) Nivel 10%, b) 20%, c) 30%, d) 40%, e) 50%, f) 60%, g) 70%, h) 80%, i) 90% y j) 100%

En la Figura 39, se puede observar que a medida que aumenta la intensidad del ruido aumenta la cantidad de fallos inducido, que es el propósito del experimento. Las medidas de desempeño de este experimento se muestran en la Tabla 10.

Tabla 10. Medidas de desempeño de todos los experimentos en el caso de estudio Nro 3

Medida de desempeño	Unidad de medida	Medición							
		Algoritmo 1			Algoritmo 2				
		Sec 1	Sec 2	Sec 3	Sec 4	Sec 1	Sec 2	Sec 3	Sec 4
Tiempo de ejecución	Segundos	0.09 46	0.0 188	0.0 069	0.0 137	0.1 435	0.0 782	0.0 242	0.0 503
Fallos inducidos	Número	668	968	455	863	668	968	455	863
Fallos inducidos y aislados (verdaderos positivos).	Número	317	483	247	422	606	896	422	807
Eventos que no son fallo y que son aislados de esta manera (verdaderos negativos).	Número	3579	594 5	273 4	596 7	339 4	566 6	260 3	567 3

Medida de desempeño	Unidad de medida	Medición							
		Algoritmo 1				Algoritmo 2			
		Sec 1	Sec 2	Sec 3	Sec 4	Sec 1	Sec 2	Sec 3	Sec 4
Eventos que no son fallo y aislado de esta manera (falsos positivos).	Número	4	5	3	2	189	284	134	296
Fallos inducidos y que no son aislados (falso negativo).	Número	351	485	208	441	62	72	33	56

El promedio del desempeño de todos los experimento en el caso de estudio No 3, se muestran en la Tabla 11.

Tabla 11. Evaluación de las medidas de desempeño de todos los experimentos en el caso de estudio No 3

Medida de desempeño	Algoritmo 1	Algoritmo 2
Sensibilidad	38.63%	90.59%
Especificidad	99.90%	94.84%

5 Discusión de resultados

En este capítulo se presenta el análisis y comparación de las medidas de desempeño mencionadas en el capítulo 3.3.2 para los dos algoritmos. Estas medidas se obtienen del proceso de generación de datos con los casos de estudios.

5.1 Fallos inducidos

5.1.1 Fallos inducidos y detectados por los algoritmos

A continuación, se presenta la comparación de los fallos inducidos con los fallos que detecta cada algoritmo

En el diagrama de líneas mostrado en la Figura 40, la línea azul corresponde al promedio de los fallos inducidos en todos los experimentos, en los diferentes niveles de intensidad de ruido, la línea en rojo corresponde al promedio de detecciones del algoritmo 1 en todos los experimentos y la línea en amarillo el mismo tipo de información que la línea en rojo, pero para el algoritmo 2.

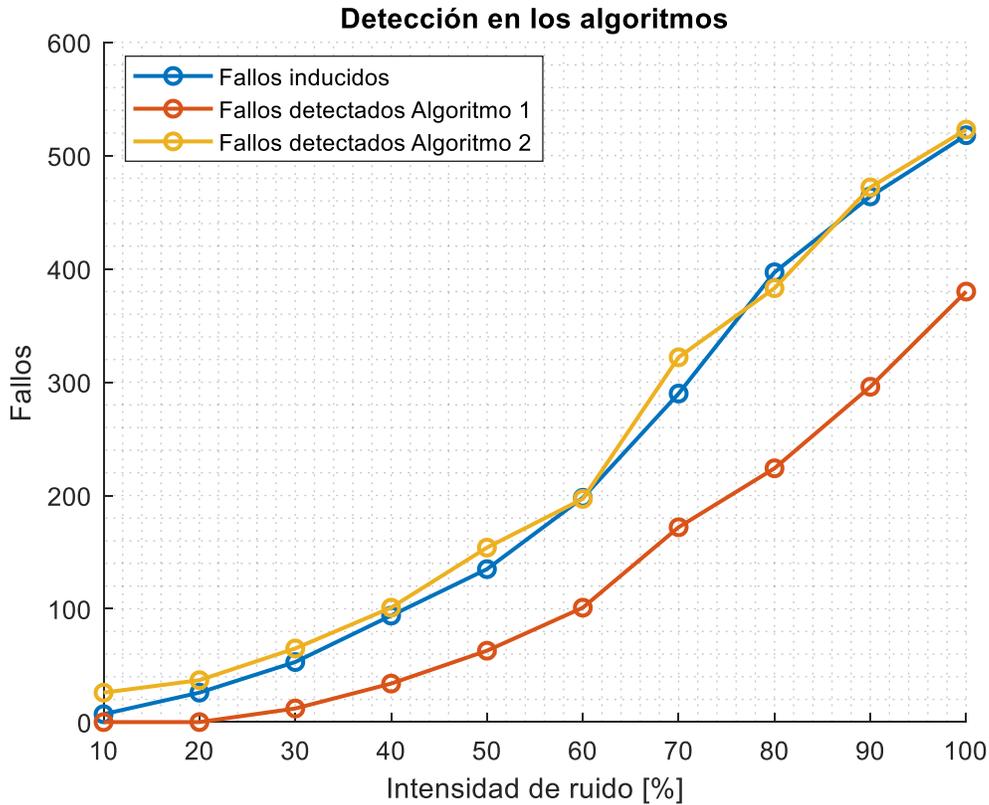


Figura 40. Fallos inducidos y detectados, caso de estudio No. 1

De acuerdo a la información de la Figura 44, se observa que el algoritmo 1 no detecta todos los fallos inducidos, comportamiento que se es más crítico a medida que los fallos son más severos, esta situación se conoce como aumento de los falsos negativos; por otro lado, el algoritmo 2, detecta la mayor parte de los fallos; pero incurre en pequeñas inconsistencias dado que detecta más fallos que los que se inducen generando lo que se conoce como falsas alarmas.

En la Figura 41 se compilan los resultados del caso 2, cuyas líneas tienen las mismas etiquetas que para el caso anterior.

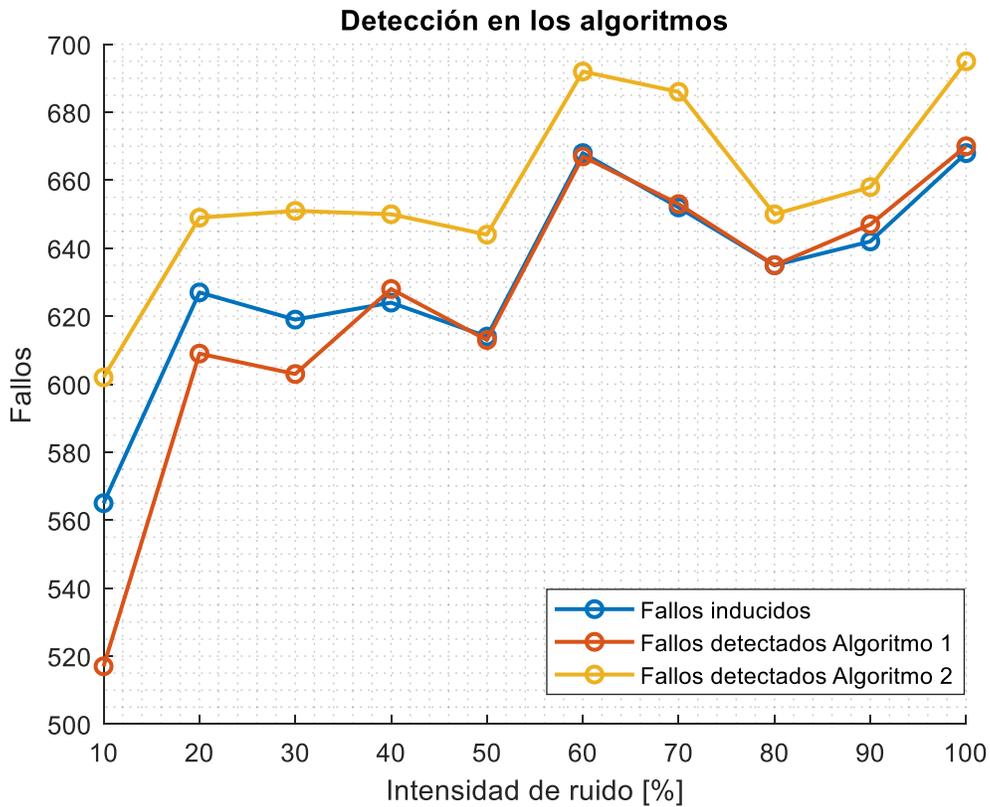


Figura 41. Fallos inducidos y detectados, caso de estudio No. 2

En el caso 2, el algoritmo 1 tiene un mejor desempeño respecto a los falsos negativos que en el caso 1, sobre todo por encima de una intensidad del ruido del 50%; pero el algoritmo 2 incrementa las falsas alarmas.

Caso 3

La Figura 42 presenta los resultados del caso 3, cuyas líneas tienen las mismas etiquetas que para el caso 1.

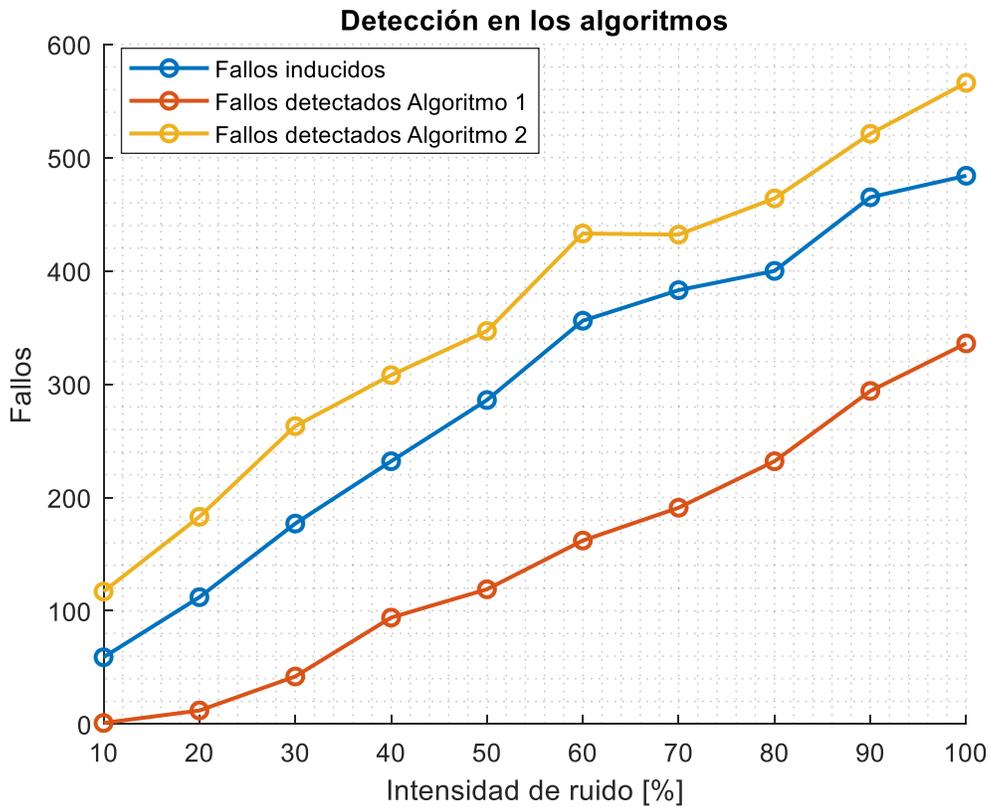


Figura 42. Fallos inducidos y detectados, caso de estudio No. 3

En este caso se puede observar que el algoritmo 1 mantiene una brecha a medida que aumenta la intensidad del ruido respecto a los falsos negativos y el algoritmo 2 mantiene una brecha respecto a los falsos positivos.

5.1.2 Falsas alarmas

En seguida se muestra la comparación de las falsas alarmas generadas por cada algoritmo en los diferentes casos de estudios.

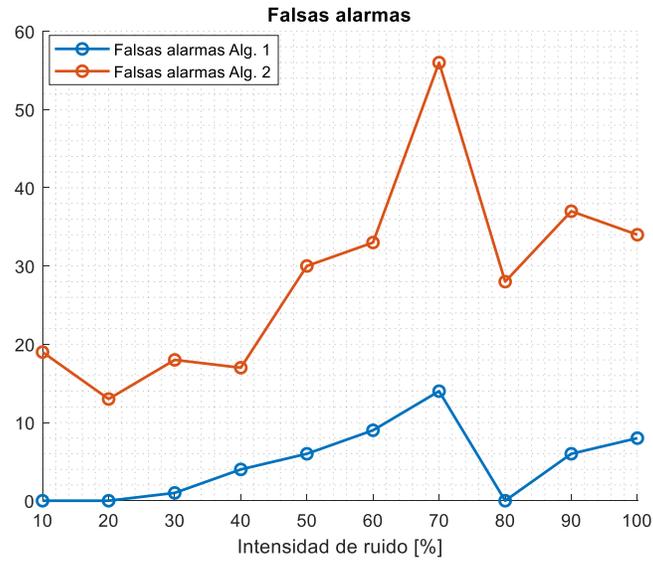


Figura 43. Falsas alarmas, caso de estudio No. 1

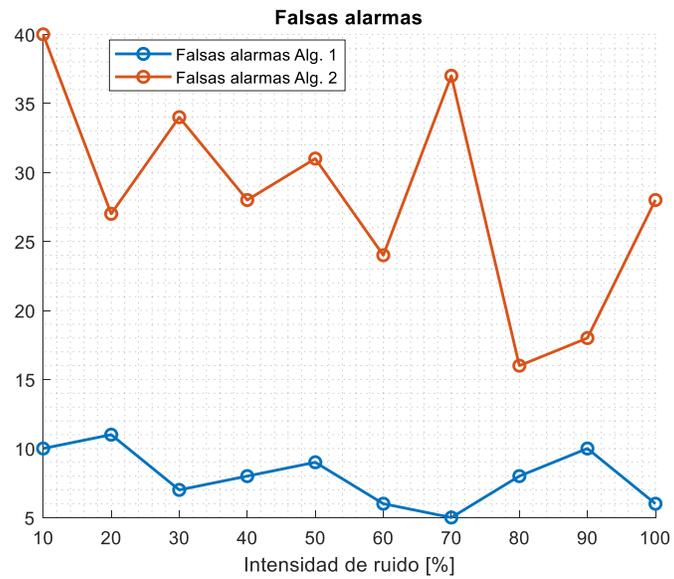


Figura 44. Falsas alarmas, caso de estudio No. 2

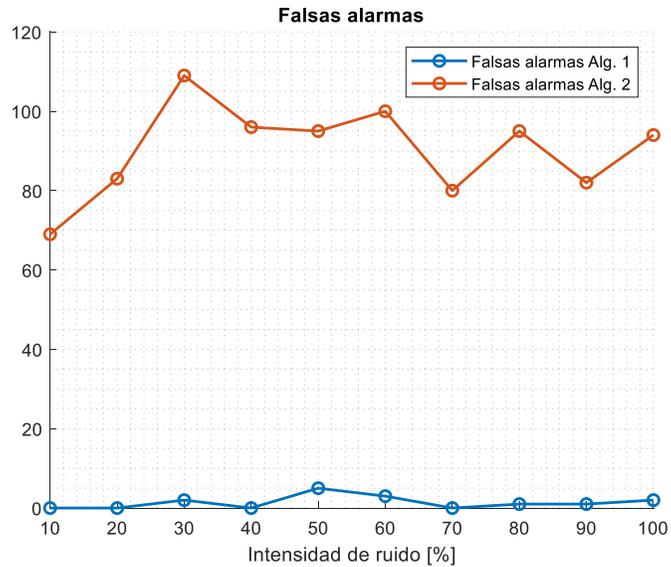


Figura 45. Falsas alarmas, caso de estudio No. 3

En la Figura 43, la Figura 44y la Figura 45 se presentan las falsas alarmas del algoritmo 1 grafica color azul y en rojo las falsas alarmas del algoritmo

Las falsas alarmas del algoritmo 2 en todos los casos de estudio son mayores a las del algoritmo 1 en todos los niveles de intensidad de fallo.

También se puede apreciar que no existe una relación entre mayor son los fallos inducidos aumente o disminuya las falsas alarmas.

5.2 Sensibilidad y especificidad

5.2.1 Sensibilidad y especificidad comparada con intensidad de ruido

A continuación, se presenta la comparación de la sensibilidad y la especificidad con los niveles de intensidad de ruido.

Para el caso de estudio número 1 se comparan los valores de sensibilidad y especificidad de todos los experimentos descritos en la Tabla 3 por medio de un diagrama de cajas y bigotes

presentados en la Figura 46 y Figura 47, de color azul se encuentra la sensibilidad y en rojo la especificidad.

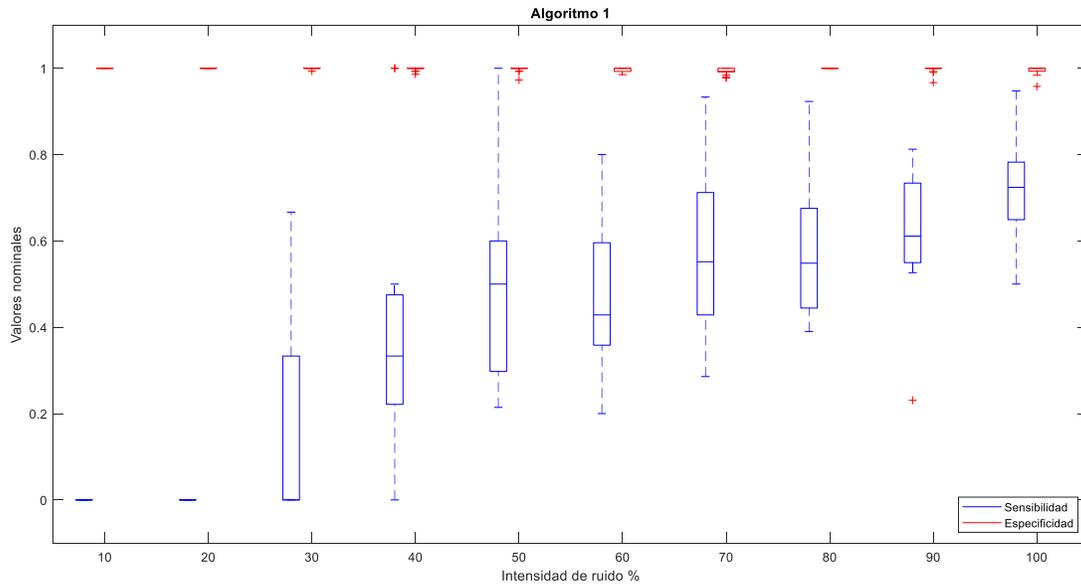


Figura 46. Sensibilidad y especificidad del algoritmo No. 1, caso de estudio No. 1

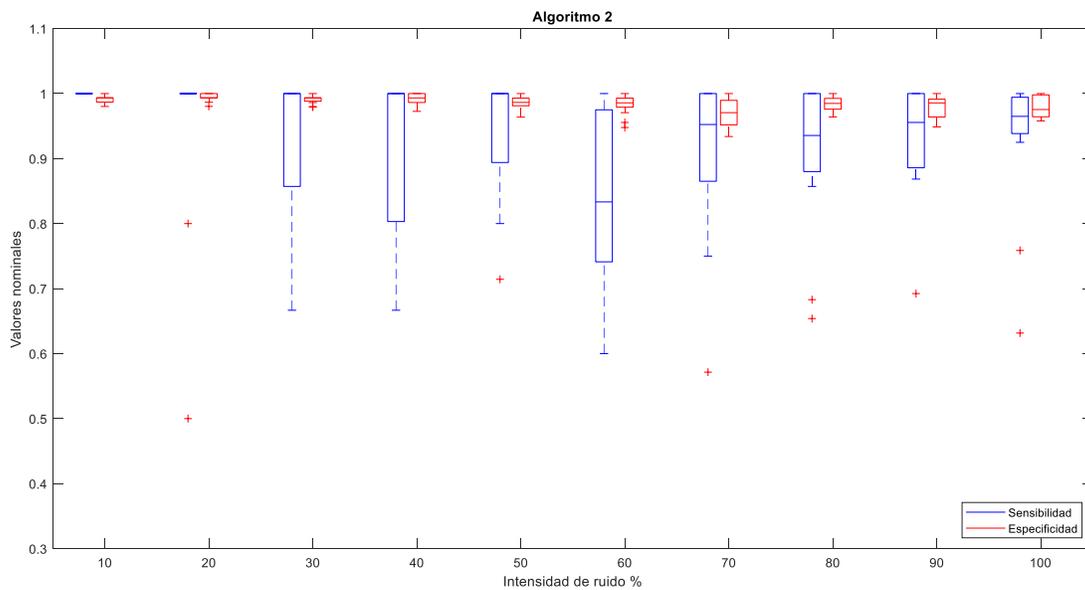


Figura 47. Sensibilidad y especificidad del algoritmo No. 2, caso de estudio No 1

Analizando el comportamiento de la sensibilidad, que mide la capacidad de detectar correctamente un fallo, para el algoritmo 1 en el caso 1 aumenta a medida que aumenta la

intensidad del ruido y los valores promedio están por debajo del 70%. La sensibilidad para el algoritmo 2 su desempeño es mejor.

Respecto a la especificidad el desempeño de los dos algoritmos en el caso No 1 es similar y su valor está por encima del 95%; es decir los dos algoritmos clasifican correctamente los eventos libres de fallo.

Para el caso de estudio número 2 se comparan los valores de sensibilidad y especificidad de todos los experimentos descritos en la Tabla 6 por medio de un diagrama de cajas y bigotes presentados en la Figura 48 y Figura 49, de color azul se encuentra la sensibilidad y en rojo la especificidad.

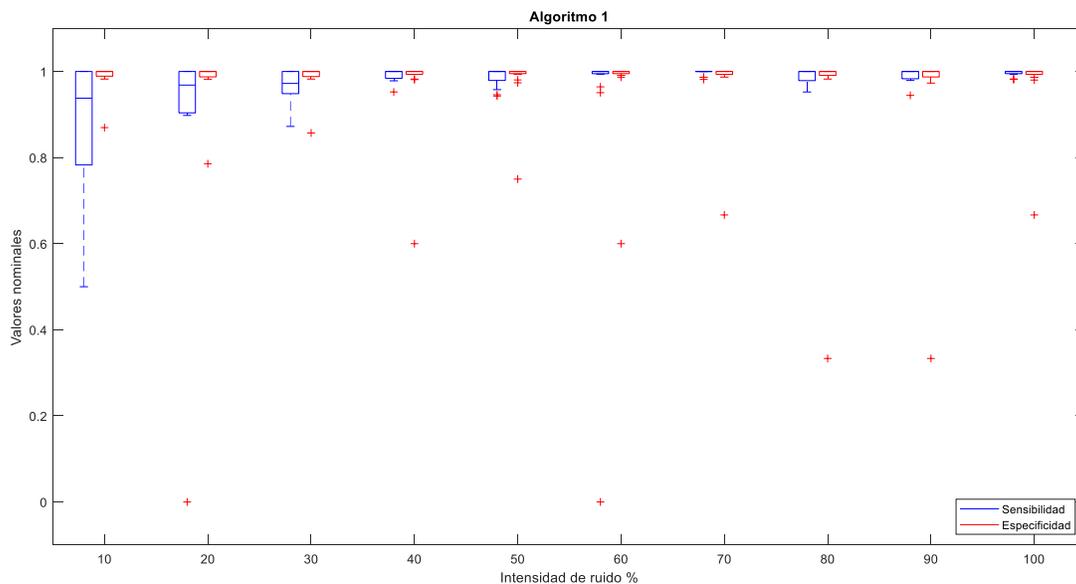


Figura 48. Sensibilidad y especificidad del algoritmo No. 1

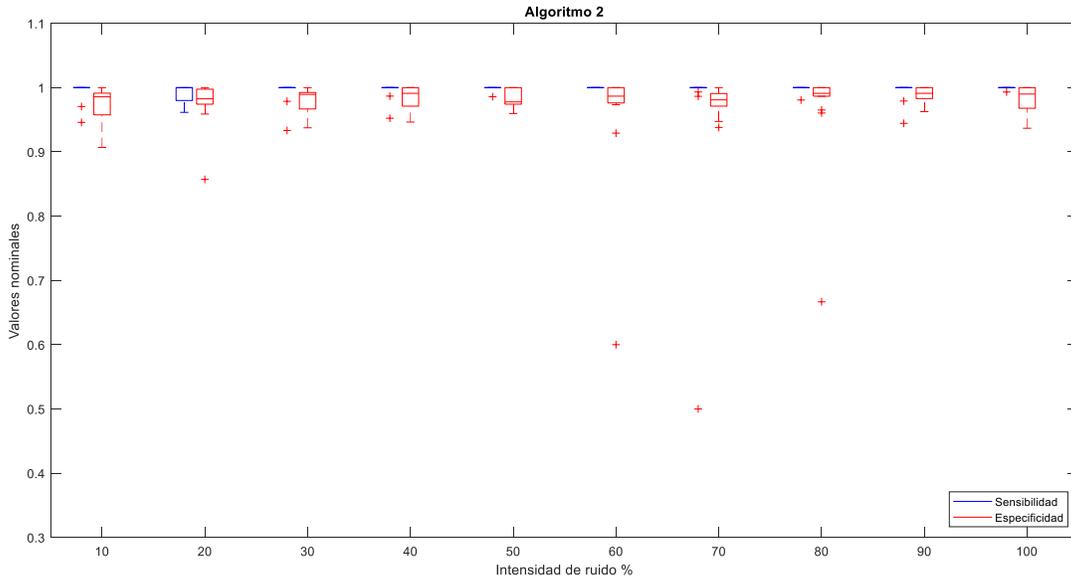


Figura 49. Sensibilidad y especificidad del algoritmo No. 2

El desempeño de los dos algoritmos en el caso de estudio No 2 en cuanto a la sensibilidad y la especificidad son muy buenos, con valores por encima del 95% y además estos indicadores no se ven afectados por la intensidad del ruido.

Para el caso de estudio número 3 se comparan los valores de sensibilidad y especificidad de todos los experimentos descritos en la Tabla 3 por medio de un diagrama de cajas y bigotes presentados en la Figura 50 y Figura 51, de color azul se encuentra la sensibilidad y en rojo la especificidad.

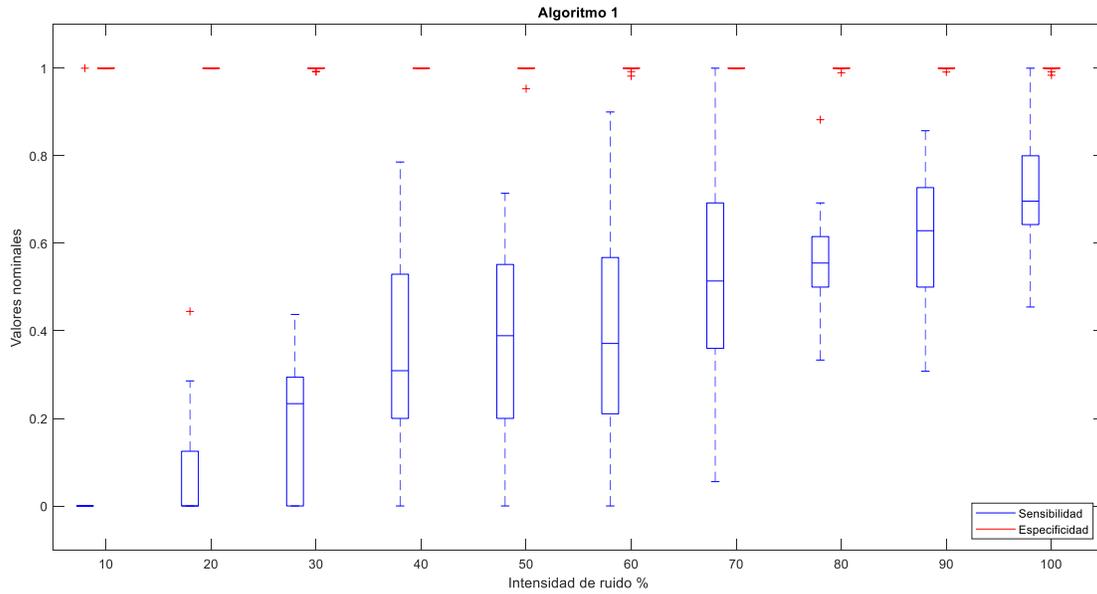


Figura 50. Sensibilidad y especificidad del algoritmo No. 1, caso de estudio No. 3

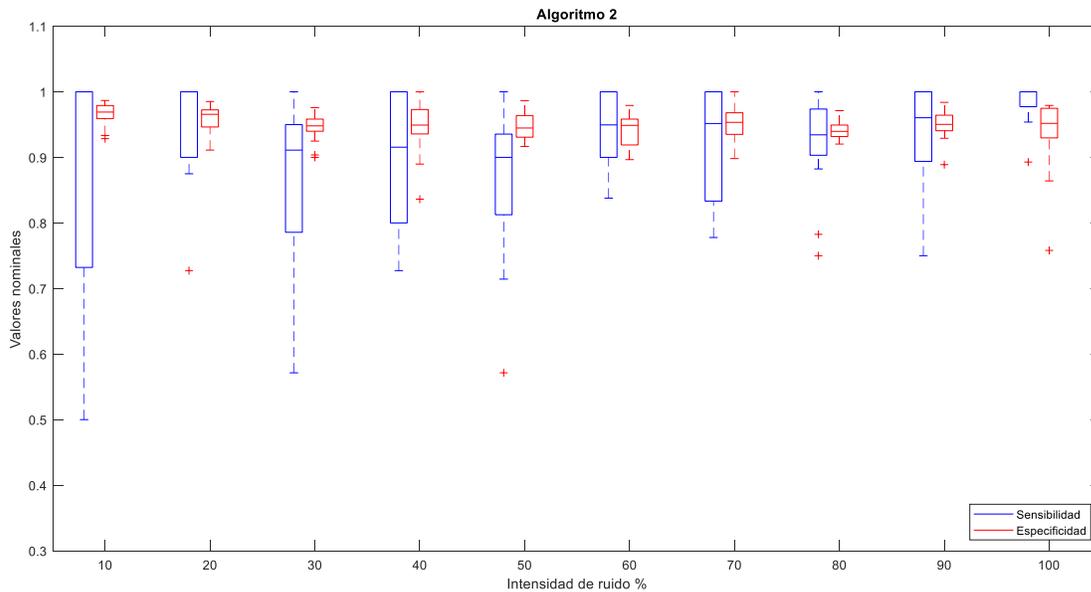


Figura 51. Sensibilidad y especificidad del algoritmo No. 2, caso de estudio No. 3

Para el caso No 3, la especificidad de los dos algoritmos es muy buena, con valores por encima del 95% y sin afectación de la intensidad del ruido. Respecto a la sensibilidad, su desempeño para el algoritmo 1 depende de la intensidad del ruido y tiene valores por debajo del 80%, mientras que el algoritmo 2 sus valores están por encima del 90%

5.2.2 Sensibilidad

En esta sección se presentan los datos de comparación de la sensibilidad de los dos algoritmos por cada experimento realizado en el caso de estudio número 1 (Figura 52).

La sensibilidad del algoritmo 1 por cada experimento es dispersa en comparación con el algoritmo 2, pero la sensibilidad del algoritmo 1 es mejor que la del algoritmo 2 a lo largo de todos los experimentos.

Al realizar un análisis ANOVA para identificar las diferencias estadísticas entre la sensibilidad del algoritmo 1 y 2, resulta, como era de esperarse que existe una diferencia significativa en los dos algoritmos.

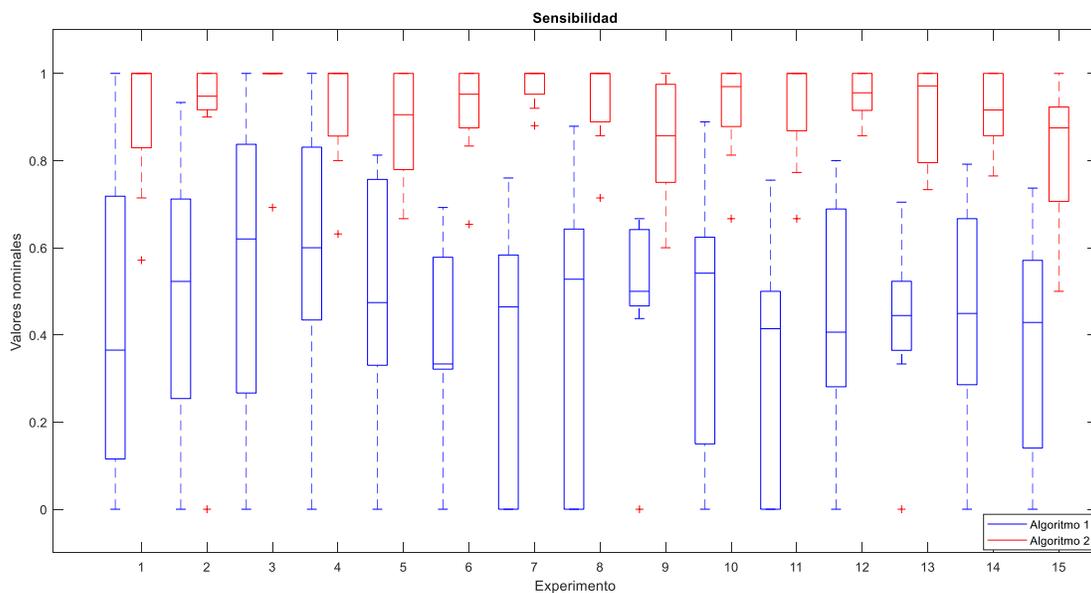


Figura 52. Sensibilidad algoritmo 1 y 2, caso de estudio No. 1

En la Figura 53 se presentan una comparación de la sensibilidad del algoritmo 1 y 2 en el caso de estudio número 2, allí se puede observar que la sensibilidad del algoritmo 1 en cada experimento es dispersa en comparación con el algoritmo 2 y para los dos algoritmos, existe una tendencia de valores cercanos a 1 para cada experimento; lo anterior significa que los dos algoritmos tienen la capacidad de detectar correctamente un fallo existente.

Para los primeros experimentos la sensibilidad es muy baja debido a que la intensidad de fallo es baja y no genera ningún evento fallo.

Al realizar un análisis ANOVA para identificar las diferencias estadísticas entre la sensibilidad del algoritmo 1 y 2, resulta que existe una diferencia significativa entre dos algoritmos en los experimentos 9, 12 y 15.

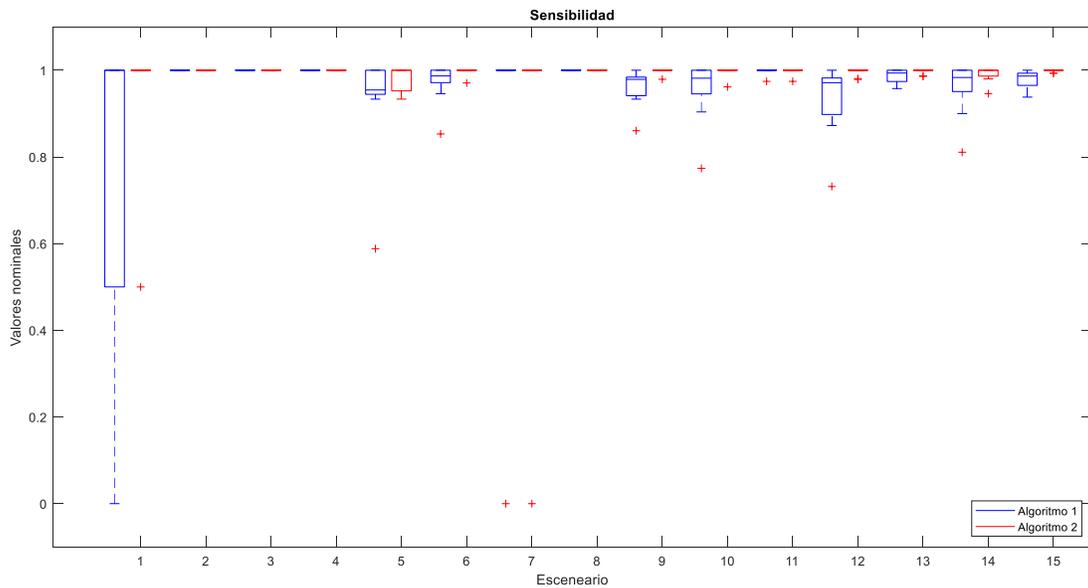


Figura 53. Sensibilidad algoritmo 1 y 2, caso de estudio No. 2

En la Figura 54 se compara la sensibilidad del algoritmo 1 y 2 en el caso de estudio número 3, se observa que la sensibilidad del algoritmo 1 por cada experimento es dispersa en comparación con el algoritmo 2, pero no son iguales, como se comprueba al realizar un análisis ANOVA para identificar las diferencias estadísticas entre la sensibilidad del algoritmo 1 y 2.

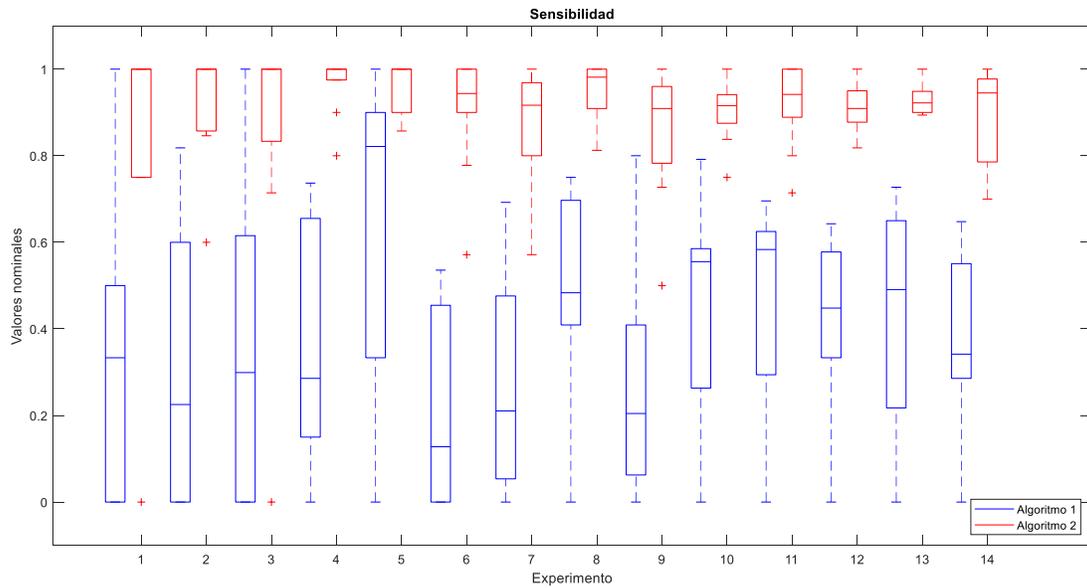


Figura 54. Sensibilidad algoritmo 1 y 2, caso de estudio No. 3

En general el algoritmo 2 tiene un mejor desempeño en cuanto a sensibilidad que el algoritmo 1 en los casos simulados.

5.2.3 Especificidad

En esta sección se presentan los datos de comparación de la especificidad de los dos algoritmos por cada experimento realizado en el caso de estudio número 1 (ver Figura 55).

Al realizar un análisis ANOVA para identificar las diferencias estadísticas entre la especificidad de los algoritmos 1 y 2, resulta que existe una diferencia significativa en los dos algoritmos a excepción del experimento 5, 10, y 15 (ver Figura 55).

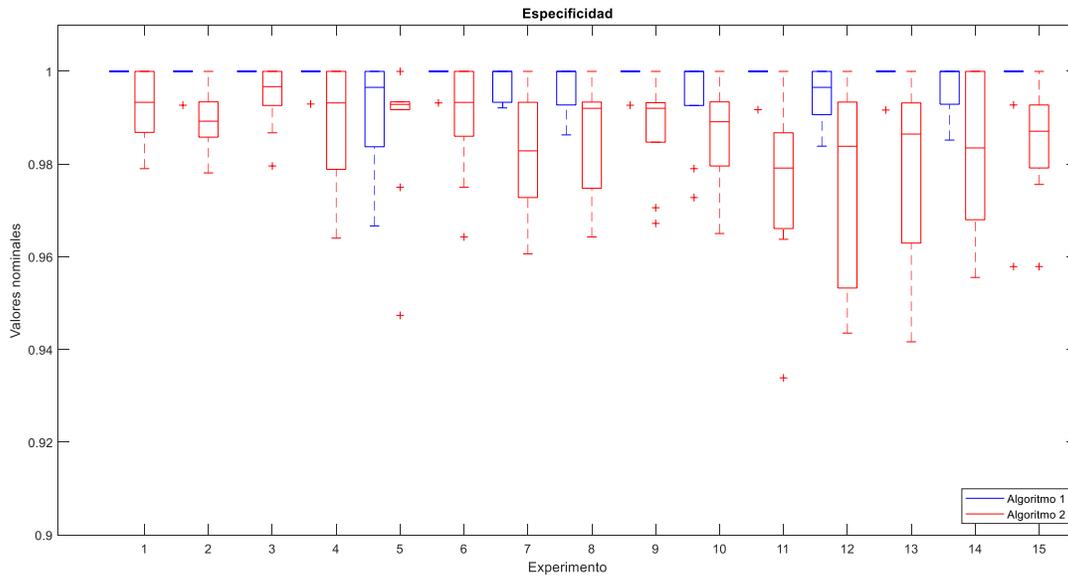


Figura 55. Especificidad algoritmo 1 y 2, caso de estudio No. 1

En la Figura 56 se presentan un diagrama de cajas y bigotes, en color azul la esta distribución que tienen los conjuntos de datos de especificidad del algoritmo 1 y en color rojo el algoritmo 2. La especificidad del algoritmo 1 y 2 por cada experimento es aproximadamente 1 para cada experimento a excepción del experimento 15. Lo anterior significa que los dos algoritmos tienen la capacidad de distinguir correctamente entre fallos reales y condiciones normales del sistema.

Al realizar un análisis ANOVA para identificar las diferencias estadísticas entre la especificidad del algoritmo 1 y 2, resulta que existe una diferencia significativa en los dos algoritmos a excepción del experimento 1, 7, 10, 11 y 14.

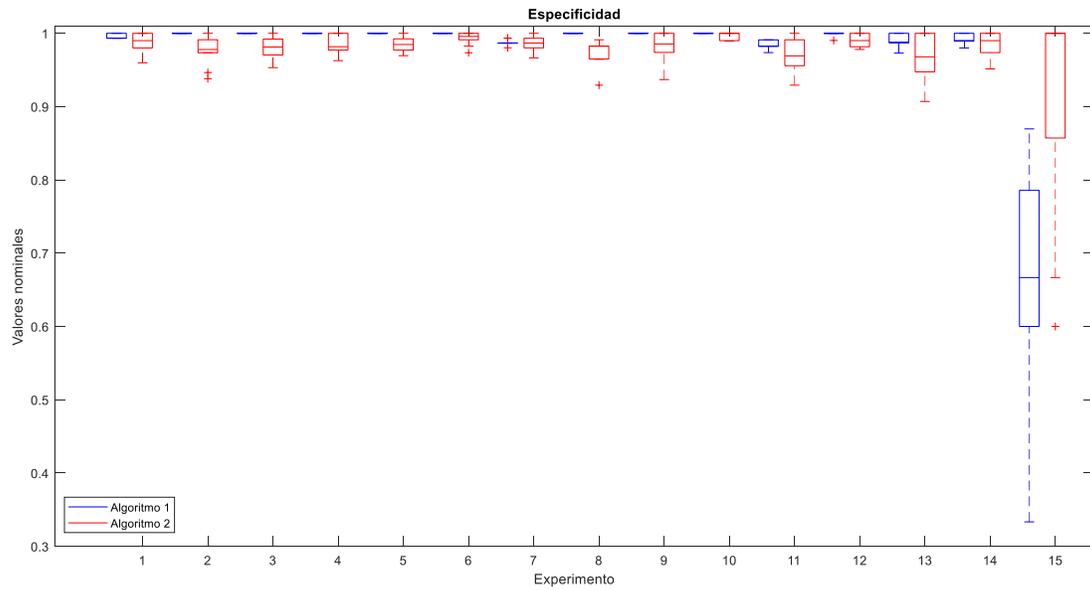


Figura 56. Especificidad algoritmo 1 y 2, caso de estudio No. 2

En la Figura 57 se presentan un diagrama de cajas y bigotes, en color azul la esta distribución que tienen los conjuntos de datos de especificidad del algoritmo 1 y en color rojo el algoritmo 2. La especificidad del algoritmo 1 y 2 por cada experimento es aproximadamente 1 para cada experimento en particular para el algoritmo 1. Lo anterior significa que los dos algoritmos tienen la capacidad de distinguir correctamente entre fallos reales y condiciones normales del sistema.

Al realizar un análisis ANOVA para identificar las diferencias estadísticas entre la especificidad del algoritmo 1 y 2, resulta que existe una diferencia significativa en los dos algoritmos.

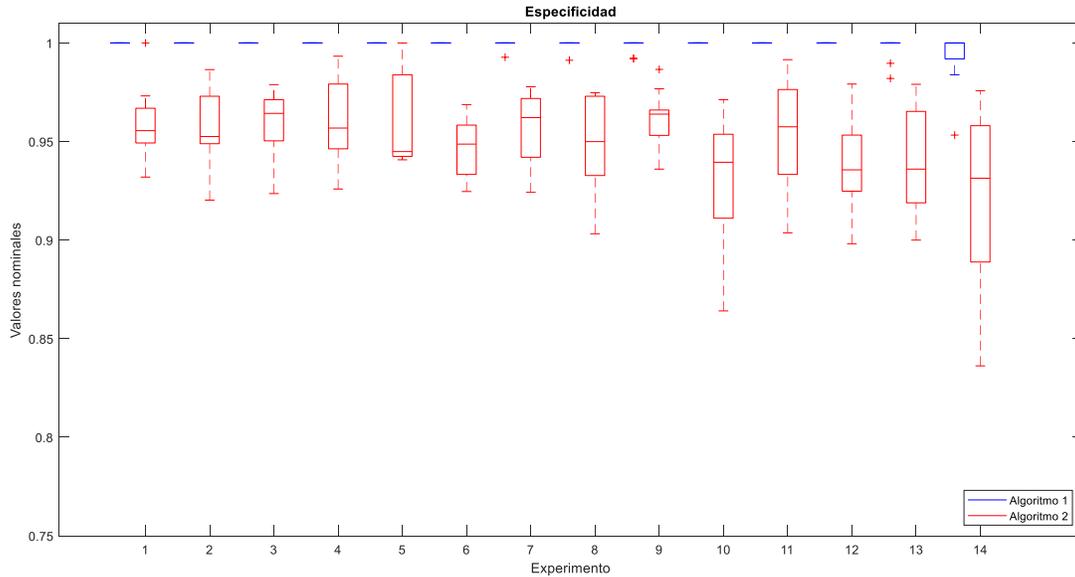


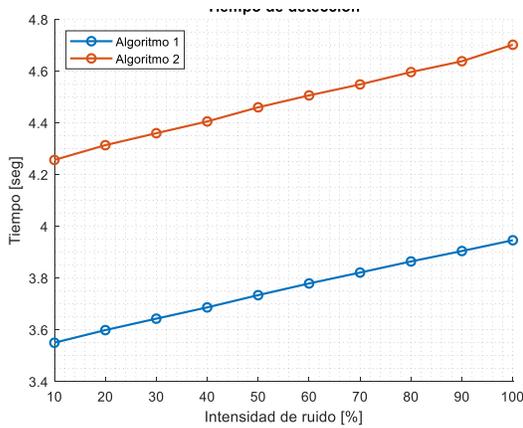
Figura 57. Especificidad algoritmo 1 y 2, caso de estudio No. 3

Respecto a la especificidad, de manera general el algoritmo 1 tiene un mejor desempeño.

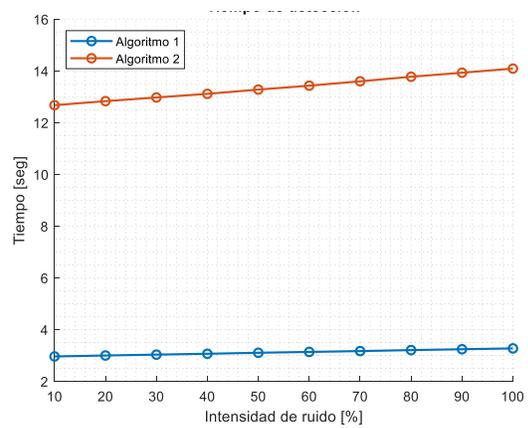
5.3 Tiempo de ejecución

A continuación, se presenta la comparación de los tiempos de ejecución de los dos algoritmos en el proceso de FDI de fallos para cada caso de estudio.

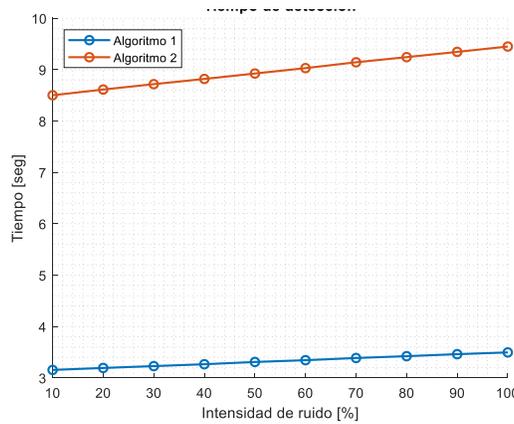
En la Figura 58 están las gráficas que corresponden al tiempo de ejecución del algoritmo 1 en color azul y algoritmo 2 en rojo. En cada caso de estudio el tiempo es diferente y el algoritmo 2 tarda más tiempo en ejecución, además los dos algoritmos tardan más tiempo entre mayor sea el nivel de intensidad de fallo.



a) Caso de estudio No. 1



b) Caso de estudio No. 2



c) Caso de estudio No. 3

Figura 58. Tiempo de ejecución por cada caso de estudio

En este capítulo se realizó el análisis y la comparación de las medidas de desempeño, en estas se puede encontrar que el proceso de detección de fallos del algoritmo 1 se reportan pocas falsas alarmas, en la medida de sensibilidad, el algoritmo 2 tiene mayor sensibilidad en el proceso FDI y por último en los tiempos de ejecución el algoritmo 1 es más rápido en su ejecución.

Con lo anterior, se puede decir que el algoritmo 1 tiene la capacidad de detectar correctamente los eventos de fallos y libres de fallos, así como la capacidad de realizar este proceso en un tiempo reducido en comparación con el algoritmo 2.

6 Comparación de los algoritmos en un modelo identificado de un sistema estocástico con comportamiento no observable

Con el objeto de verificar el comportamiento de los algoritmos de FDI en un entorno industrial, dentro del desarrollo de la investigación se propuso un método de identificación de sistemas de eventos discretos con un comportamiento particular. Este comportamiento genera algunos cambios en la dinámica interna del sistema, sin que se hayan generado cambios en las señales de entrada – salida. Este tipo de sistemas provocan comportamientos no observables, cuyas causas pueden ser, entre otras, la escasez de sensores.

El método se denomina “Identificación del comportamiento no observable en sistemas de eventos estocásticos con bajo número de sensores” [41]. El método se compone de dos etapas: identificación de la estructura de una red de Petri interpretata temporizada estocástica, st-IPN, a partir de secuencias de eventos cronometrados observados y la adición del comportamiento no observable a la estructura st-IPN identificada, sobre la proyección de lenguajes.

El método [41] se aplicó a un proceso industrial cuyo comportamiento evoluciona a partir de estados. El objetivo del proceso es pegar una almohadilla blanda sobre un reposabrazos. La línea dispone de un transportador, un inyector de cola con movimiento deslizante, una tolva de almohadillas con cinta inclinada, un dispensador y colocador de almohadillas, una estación de prensado de almohadillas con vibrador, cilindros a lo largo de la línea que realizan la función de barrera y control de tráfico, una estación de envoltura automática y una pantalla HMI, donde se realiza la parametrización, control y supervisión de todo el sistema. La planta en estudio tiene un comportamiento estocástico y está instrumentada con seis sensores y 16 actuadores que se enumeran a continuación:

- **Sensores:** Sensor réflex 1, Sensor réflex 2, Sensor réflex 3, Sensor réflex 4, Sensor de proximidad 1 y Sensor de proximidad 2.
- **Actuadores:** Cilindro de barrera 1, Cilindro de barrera 2, Inyector de cola de marcha, Cilindro esparcidor de cola, Cilindro de barrera 3, Cilindro de barrera 4, Cilindro posicionador 1, Cilindro colocador de almohadillas, Cilindro de barrera 5, Cilindro prensador, Cilindro posicionador 2, Vibración de marcha y Envolvedor giratorio de marcha.

Aplicando el algoritmo propuesto el modelo que representa el comportamiento observable, se muestra en la Figura 59, de igual manera, el modelo con comportamiento no observable en la Figura 60.

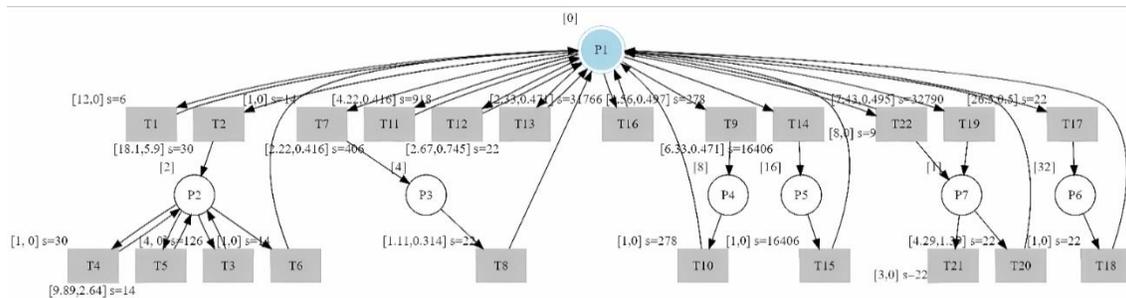


Figura 59. Modelo del sistema

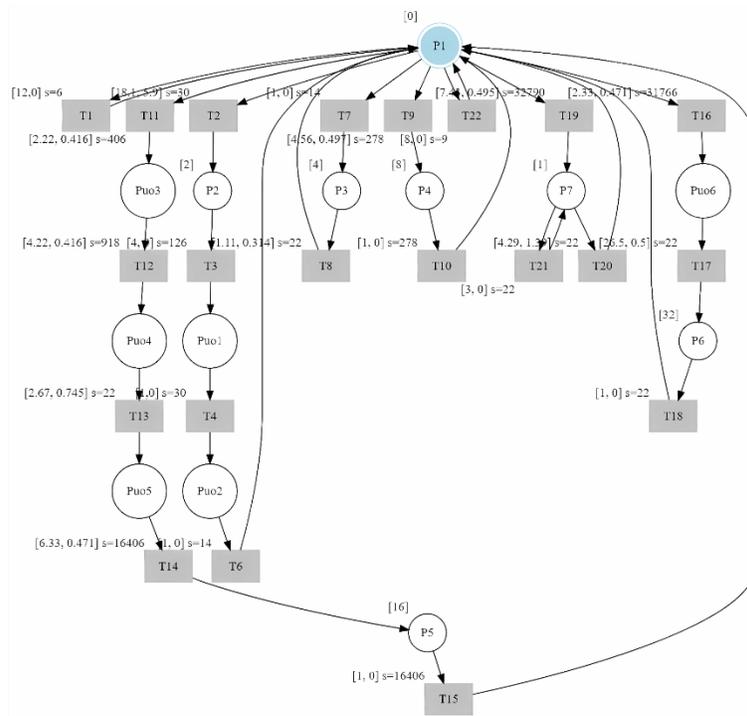


Figura 60. Modelo con comportamiento no observable

Sobre el modelo encontrado, se aplicó el proceso de experimentación propuesto en el capítulo 3.

Las secuencias de eventos que definen el comportamiento del sistema son: $sec_1 = (e_1)$, $sec_2 = (e_{11}e_{12}e_{13}e_{14}e_{15})$, $sec_3 = (e_2e_3e_4e_6)$, $sec_4 = (e_7e_8)$, $sec_5 = (e_9e_{10})$, $sec_6 = (e_{22})$, $sec_7 = (e_{19}e_{21}e_{20})$, $sec_8 = (e_{16}e_{17}e_{18})$.

Se ejecutaron 6058 repeticiones sobre el modelo encontrado, en donde en cada ciclo se generaron secuencias de eventos de la t-IPN de manera aleatoria, considerando el comportamiento estocástico de cada transición. Una vez se obtuvo la información temporizada del modelo libre de fallos, se inició el proceso de experimentación. Para ello se definieron los escenarios:

Tabla 12. Escenarios de experimentación comportamiento no observable

Experimento	Transiciones manipuladas	Intensidad del fallo (\pm)
1	$\{t_{16}\}$	10%, 20%, 30%, 40%, 50%, 60%, 70%, 80%, 90% y 100%.
2	$\{t_{19}\}$	
3	$\{t_2, t_3\}$	
4	$\{t_{11}, t_{12}, t_{13}, t_{14}\}$	

Las medidas de desempeño de este experimento se muestran en la Tabla 13.

Tabla 13. Medidas de desempeño de todos los experimentos

Medidas de desempeño		Tiempo de ejecución	Fallos inducidos	Fallos inducidos y aislados (verdaderos positivos).	Eventos que no son fallo y que son aislados de esta manera (verdaderos negativos).	Eventos que no son fallo y aislado de esta manera (falsos positivos).	Fallos inducidos y que no son aislados (falso negativo).	
Medición	Algoritmo 1	Sec 1	0.057	27	21	508	3	6
		Sec 2	0.006	45	38	1211	14	7
		Sec 3	0.008	37	31	832	11	6
		Sec 4	0.002	26	20	457	5	6
	Algoritmo 2	Sec 5	0.002	25	24	544	7	1
		Sec 6	0.002	26	25	540	12	1
		Sec 7	0.003	40	38	934	10	2
		Sec 8	0.003	26	23	707	11	3
Algoritmo 2	Sec 1	0.043	27	26	507	4	1	
	Sec 2	0.028	45	43	1206	19	2	
	Sec 3	0.037	37	36	831	12	1	

Medidas de desempeño	Tiempo de ejecución	Fallos inducidos	Fallos inducidos y aislados (verdaderos positivos).	Eventos que no son fallo y que son aislados de esta manera (verdaderos negativos).	Eventos que no son fallo y aislado de esta manera (falsos positivos).	Fallos inducidos y que no son aislados (falso negativo).
Sec 4	0.012	26	24	458	4	2
Sec 5	0.011	25	24	545	6	1
Sec 6	0.014	26	24	542	10	2
Sec 7	0.025	40	39	935	9	1
Sec 8	0.017	26	25	712	6	1

A continuación se presenta los resultados de las medidas de desempeño.

En la Figura 61 se observan las cifras de detección de fallos del algoritmo 1 (gráfica de color rojo) y algoritmo 2 (gráfica de color amarillo) según los fallos inducidos (gráfica de color azul). Los datos de detección son mayores a los fallos inducidos, esto representa falsas alarmas en el proceso de detección.

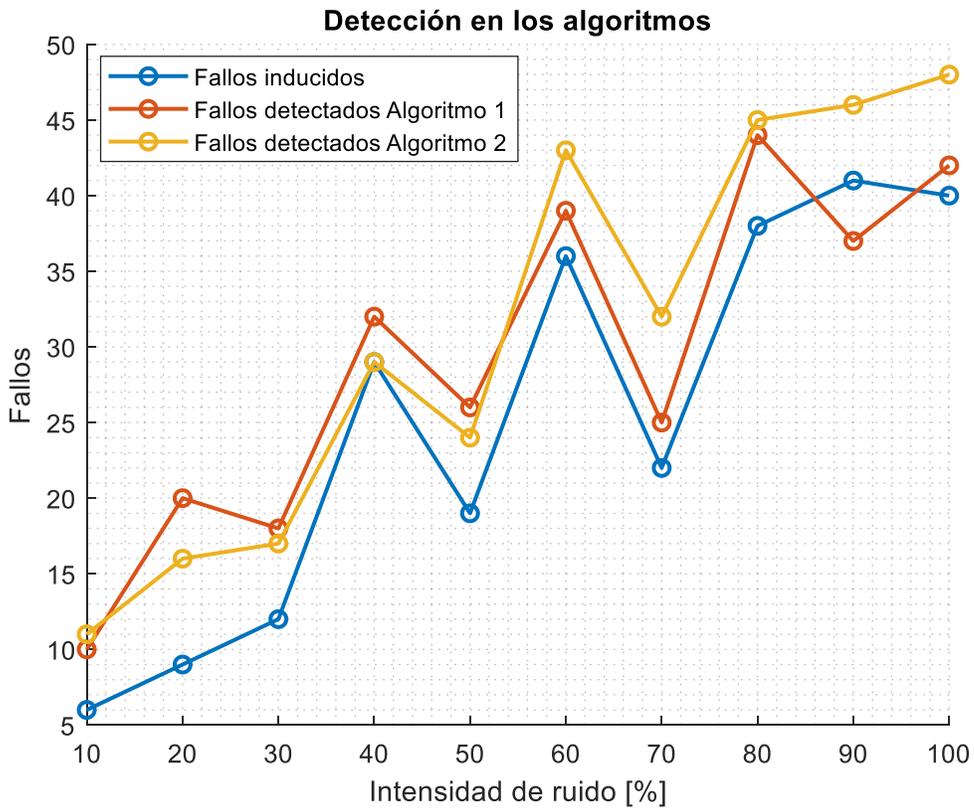


Figura 61. Fallos inducidos

En consecuencia, con lo mencionado anteriormente, según la Figura 61 existe un mayor número de falsas alarmas tanto del algoritmo 1 como del algoritmo 2 con respecto a los fallos inducidos.

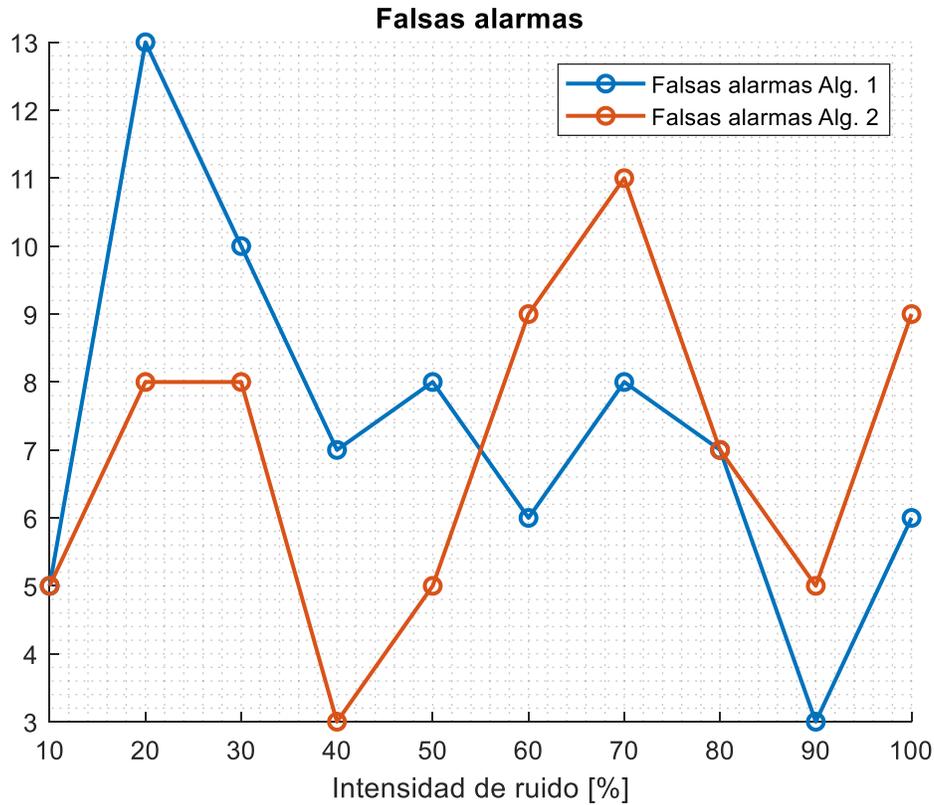


Figura 62. Fallos inducidos.

En la Figura 63 y Figura 64 se encuentran los datos de sensibilidad (color azul) y especificidad (color rojo) por cada algoritmo respectivamente y su comportamiento en cada nivel de intensidad de ruido. Los datos de los dos algoritmos tienen el mismo comportamiento en la especificidad al tener valores cercanos a 1. Lo anterior significa que los algoritmos tienen una confiabilidad para clasificar correctamente a los eventos que estén libres de fallos. La sensibilidad en este caso tiene valores con mayor variabilidad lo que significa que la capacidad que se tiene para detectar correctamente un fallo existente es variable.

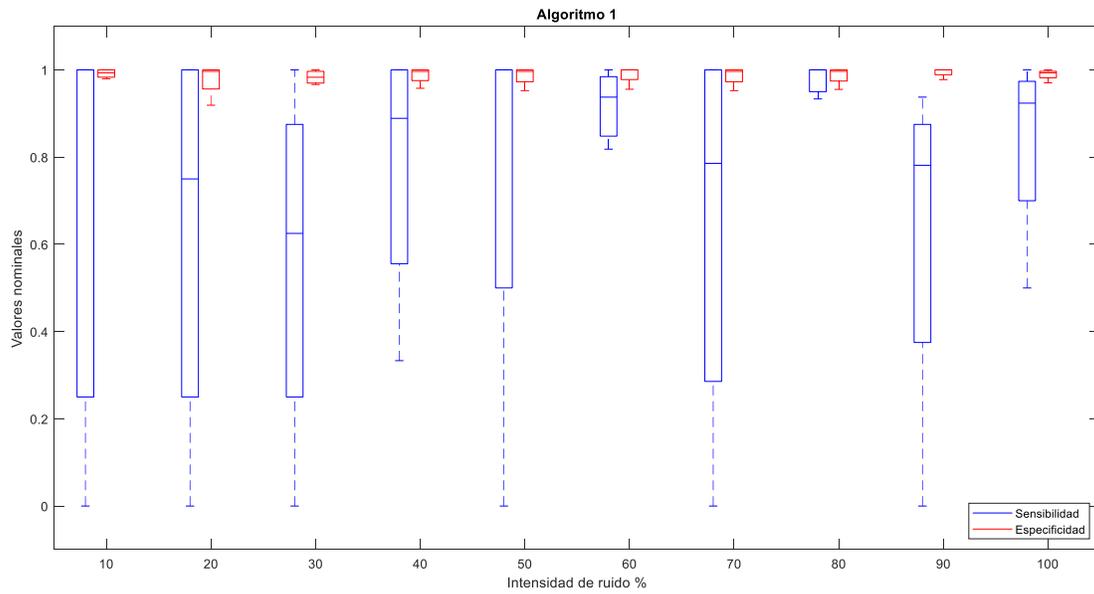


Figura 63. Sensibilidad y especificidad algoritmo 1.

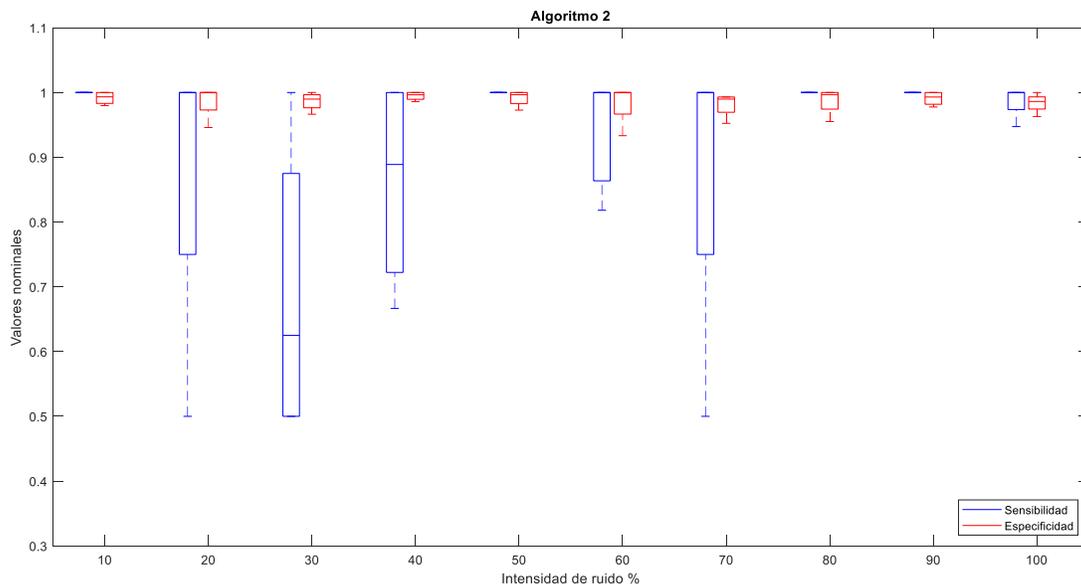


Figura 64. Sensibilidad y especificidad algoritmo 2.

A continuación, están los datos de sensibilidad (Figura 65a) y especificidad (Figura 65b) en cada escenario. Se puede deducir que concuerda con los anteriores datos al ser mayor número de eventos afectados por un fallo los algoritmos tienden a mejorar la sensibilidad y especificidad.

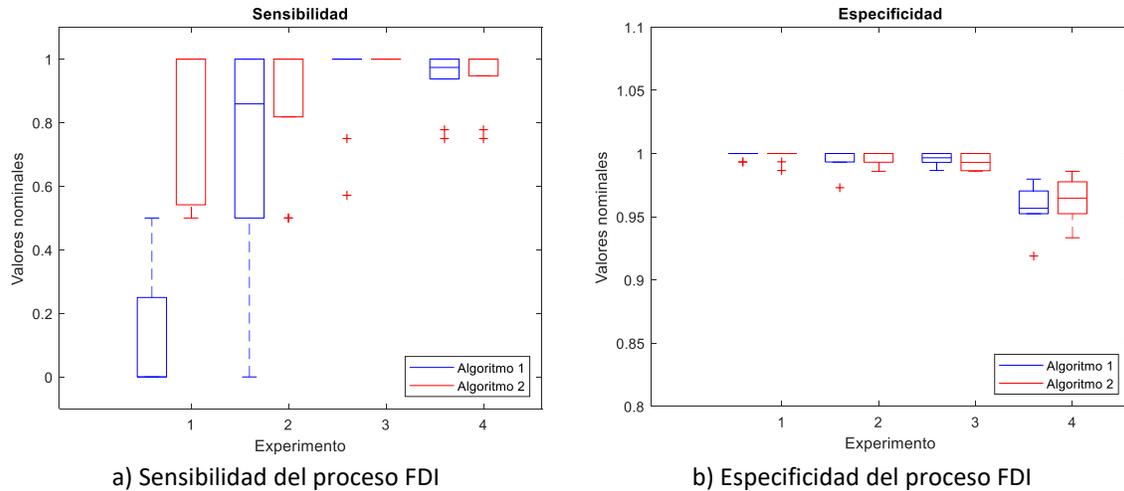


Figura 65. Sensibilidad y especificidad.

La especificidad para todos los experimentos no existe una diferencia estadísticamente significativa entre los datos, pero en el caso de la sensibilidad solo en el experimento número 1 existe una diferencia estadísticamente significativa que se comprueba con un test ANOVA presentada en la Tabla 14.

Tabla 14. Prueba ANOVA

Fuente	Suma de cuadrados	Grados de libertad	Error cuadrático medio	Valor F	Valor p
Grupos	1,668651	1	1,668651	32,346154	0,000101
Error	0,619048	12	0,051587		
Total	2,287698	13			

Por último, se encuentra el tiempo de ejecución (ver Figura 66) para los dos algoritmos por cada nivel de ruido. Existe un incremento en el tiempo de ejecución entre mayor sea el nivel de ruido del evento, esto debido a que existe una mayor probabilidad que varios eventos se encuentren en fallo y el algoritmo invierte tiempo en el proceso FDI.

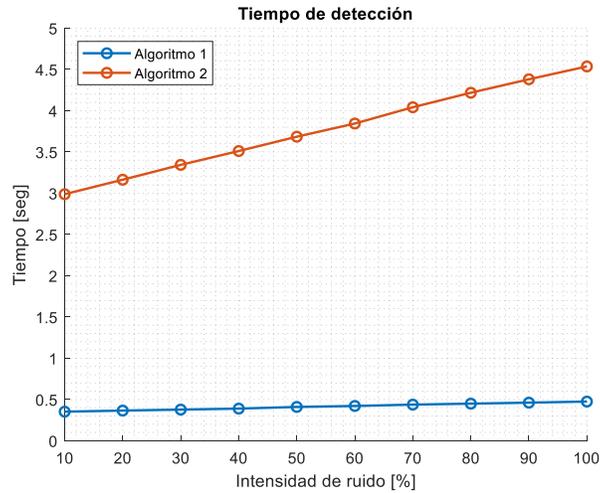


Figura 66. Tiempo de ejecución.

En este capítulo se estudió el desempeño de los algoritmos en un proceso industrial identificado con un método propuesto [41]. Este caso de estudio tiene mayor complejidad con relación a los casos ya presentados y el desempeño de los dos algoritmos es similar, para la medida de sensibilidad se evidencia que el algoritmo 2 tiene un mejor desempeño según la Figura 65a); en la medida de especificidad los dos algoritmos tienen el mismo comportamiento y es cercano a 1. Lo anterior significa que el algoritmo 2 tiene una mejor capacidad que para detectar correctamente un fallo existente y los dos algoritmos clasifican correctamente a los eventos que estén libres de fallos, adicional a la sensibilidad y especificidad de los algoritmos el algoritmo 1 es más rápido en realizar el proceso de FDI.

7 Conclusiones

Esta investigación propone una metodología que permite evaluar los métodos de FDI seleccionados. Esta metodología está basada: inicialmente en definir condiciones iniciales con el fin de comparar los métodos; en seguida se encuentra la selección de escenarios de comparación; continúa con la obtención de datos con un comportamiento libre de fallo, un comportamiento de fallo, y el proceso de detección de estos fallos; posteriormente el cálculo de las medidas de desempeño como son la sensibilidad, especificidad, falsas alarmas de detección y tiempo de ejecución; y por último la evaluación de las medidas de desempeño.

El método de diagnóstico propuesto por el algoritmo 1 presenta mejor desempeño en detección de fallos; así mismo, un bajo número de detecciones falsas en el caso de estudio número 1 un 83%, en el caso de estudio número 2 un 72% y en el caso de estudio número 3 un 98.5% menos de falsas alarmas generadas en el algoritmo 1 respecto del algoritmo 2. Una de las razones es que el proceso de clasificación de eventos de fallo o libre de fallo basado en media móvil, esta técnica utiliza de los valores de tiempo anteriores que permiten formar un comportamiento histórico sin el uso de cálculos complejos.

El desempeño del algoritmo 2 fue mejor en comparación con el algoritmo 1 en la medida de desempeño de sensibilidad. En el caso de estudio 1 con 46.94%, en el estudio 2 con 2.6% y el estudio 3 con 51.96% superior en sensibilidad que el algoritmo 1. Lo anterior significa que el algoritmo 2 tiene una mejor capacidad para detectar correctamente un fallo existente, esto se debe, a la técnica usada que requiere de un número mayor de operaciones y comparaciones para realizar el proceso de FDI.

Los valores de especificidad para los dos algoritmos fueron similares y sus diferencias fueron pequeñas, en el caso de estudio número 1 y 3 existe una diferencia entre los algoritmos de 1.21% y 5.06%, siendo superior el algoritmo 1; pero en el caso de estudio número 2 existe una diferencia de 0.47% siendo superior el algoritmo 2. Esto demuestra la capacidad del

algoritmo 1 para distinguir correctamente entre fallos reales y condiciones normales del sistema.

El algoritmo 1 presentó en los diferentes datos recolectados, un tiempo menor de ejecución durante el proceso de FDI, en el caso de estudio 1 con 15.56%, en el caso 2 con 76.9% y en el caso 3 con 63.3% más rápido que el algoritmo 2. Lo anterior se debe a que el algoritmo 1 no necesita operaciones complejas para realizar este proceso; el caso contrario sucede con el algoritmo 2 que tiene un mayor tiempo de ejecución, esto se debe al método de detección basado en el cálculo de residuales.

Se propone un método de identificación de sistemas dinámicos con un bajo número de sensores que permite modelar el sistema por medio de un modelo con comportamiento no observable. Este modelo representa sistemas dinámicos encontrados en el sector industrial como por ejemplo en de manufactura. La identificación está basada en el análisis de señales de entrada y salida del sistema lo que permite analizar el cambio de estado del sistema. Este modelo identificado permitió evaluar el desempeño de los dos algoritmos, en donde el desempeño del algoritmo 2 se destacó por tener valores promedios de sensibilidad con 22% mejor que el algoritmo 1; en cuanto a la especificidad los dos algoritmos tienen similar desempeño con un promedio de 98.7%; por último, el tiempo de ejecución del algoritmo 1 fue 89% mejor que el algoritmo 2.

7.1 Trabajos futuros

El presente trabajo compara el desempeño de dos algoritmos de detección y aislamiento de fallos en sistemas de eventos discretos estocásticos y define una metodología para su aplicación; como trabajo futuro se propone aplicar la metodología para detectar comportamientos de fallo temporales en sistemas de gran escala cuando se presentan fallos de propagación.

8 Bibliografía

- [1] C. G. Cassandras and S. Lafortune, *Introduction to discrete event systems*. Kluwer Academic, 1999.
- [2] D. Lefebvre, S. Rachidi, E. Leclercq, and Y. Pigne, “Diagnosis of Structural and Temporal Faults for k-Bounded Non-Markovian Stochastic Petri Nets,” *IEEE Trans. Syst. Man, Cybern. Syst.*, pp. 1–13, 2018.
- [3] J. Meseguer, V. Puig, and T. Escobet, “Fault Diagnosis Using a Timed Discrete-Event Approach Based on Interval Observers: Application to Sewer Networks,” *IEEE Trans. Syst. Man, Cybern. - Part A Syst. Humans*, vol. 40, no. 5, pp. 900–916, Sep. 2010.
- [4] M. Blanke, M. Kinnaert, J. Lunze, and M. Staroswiecki, *Diagnosis and Fault-Tolerant Control*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2016.
- [5] S. Schneider, L. Litz, and J. J. Lesage, “Determination of timed transitions in identified discrete-event models for fault detection,” in *Proceedings of the IEEE Conference on Decision and Control*, 2012, pp. 5816–5821.
- [6] D. Lefebvre, “Fault diagnosis for non-Markovian timed stochastic discrete event systems,” in *2017 22nd IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)*, 2017, pp. 1–7.
- [7] A. Lai, S. Lahaye, and A. Giua, “A two-step approach for fault diagnosis of max-plus automata,” in *2019 6th International Conference on Control, Decision and Information Technologies, CoDIT 2019*, 2019, pp. 1061–1066.
- [8] F. Basile, M. P. Cabasino, and C. Seatzu, “Diagnosability Analysis of Labeled Time Petri Net Systems,” *IEEE Trans. Automat. Contr.*, vol. 62, no. 3, pp. 1384–1396, Mar. 2017.
- [9] X. Yin, J. Chen, Z. Li, and S. Li, “Robust fault diagnosis of stochastic discrete event

- systems," *IEEE Trans. Automat. Contr.*, vol. 64, no. 10, pp. 4237–4244, Oct. 2019.
- [10] S. Lafortune, F. Lin, and C. N. Hadjicostis, "On the history of diagnosability and opacity in discrete event systems," *Annu. Rev. Control*, vol. 45, pp. 257–266, 2018.
- [11] R. Zemouri and J. M. Faure, "Diagnosis of discrete event system by stochastic timed automata," in *2006 IEEE Conference on Computer Aided Control System Design, 2006 IEEE International Conference on Control Applications, 2006 IEEE International Symposium on Intelligent Control*, 2006, pp. 1861–1866.
- [12] D. Lefebvre, "Probability of current state and future faults with partially observed stochastic Petri nets," in *2014 European Control Conference (ECC)*, 2014, pp. 258–263.
- [13] D. Lefebvre, "Fault probability with partially observed stochastic Petri nets," in *2014 American Control Conference*, 2014, pp. 5502–5507.
- [14] S. Rachidi, E. Leclercq, Y. Pigne, and D. Lefebvre, "Moving Average control chart for the detection and isolation of temporal faults in stochastic Petri nets," in *2018 IEEE 23rd International Conference on Emerging Technologies and Factory Automation (ETFA)*, 2018, pp. 493–498.
- [15] D. Lefebvre, "Probability of faults for partially observed Timed PNs with temporal constraints," in *2017 IEEE 14th International Conference on Networking, Sensing and Control (ICNSC)*, 2017, pp. 103–108.
- [16] D. Lefebvre and E. Leclercq, "Stochastic Petri Net Identification for the Fault Detection and Isolation of Discrete Event Systems," *IEEE Trans. Syst. Man, Cybern. - Part A Syst. Humans*, vol. 41, no. 2, pp. 213–225, Mar. 2011.
- [17] R. Ammour, E. Leclercq, E. Sanlaville, and D. Lefebvre, "Datation of Faults for Markovian Stochastic DESs," *IEEE Trans. Automat. Contr.*, vol. 64, no. 7, pp. 2961–2967, Jul. 2019.

- [18] D. Lefebvre and E. Leclercq, "Detection and isolation of temporal drifts in manufacturing systems with observers and control charts," *SN Appl. Sci.*, vol. 2, no. 7, pp. 1–19, Jul. 2020.
- [19] T. Murata, "Petri nets: Properties, analysis and applications," *Proc. IEEE*, vol. 77, no. 4, pp. 541–580, Apr. 1989.
- [20] A. T. Y. Watanabe, R. Sebem, A. B. Leal, and M. da S. Hounsell, "Fault prognosis of discrete event systems: An overview," *Annu. Rev. Control*, vol. 51, pp. 100–110, Jan. 2021.
- [21] C. Galetta, J. M. Roussel, and J. M. Faure, "A relative identification method for reactive systems," *IFAC-PapersOnLine*, vol. 51, no. 7, pp. 152–159, Jan. 2018.
- [22] D. M. Muñoz, A. Correcher, E. García, and F. Morant, "Identification of stochastic timed discrete event systems with st-IPN," *Math. Probl. Eng.*, vol. 2014, 2014.
- [23] E. Rodríguez-Pérez, T. Tapia-Flores, and E. López-Mellado, "Identification of Timed Discrete Event Processes. Building Input-Output Petri Net Models," 2016.
- [24] F. Basile, P. Chiacchio, and J. Coppola, "Identification of Time Petri Net Models," *IEEE Trans. Syst. Man, Cybern. Syst.*, vol. 47, no. 9, pp. 2586–2600, Sep. 2017.
- [25] S. Ould El Mehdi, R. Bekrar, N. Messai, E. Leclercq, D. Lefebvre, and B. Riera, "Design and identification of stochastic and deterministic stochastic petri nets," *IEEE Trans. Syst. Man, Cybern. Part A Systems Humans*, vol. 42, no. 4, pp. 931–946, Jul. 2012.
- [26] R. P. C. de Souza, M. V. Moreira, and J. J. Lesage, "Fault detection of Discrete-Event Systems based on an identified timed model," *Control Eng. Pract.*, vol. 105, p. 104638, Dec. 2020.
- [27] S. Schneider, L. Litz, and M. Danancher, "Timed residuals for fault detection and isolation in discrete event systems," in *2011 3rd International Workshop on*

Dependable Control of Discrete Systems, DCDS'11 - Conference Proceedings, 2011, pp. 35–40.

- [28] E. Leclercq, D. Lefebvre, and S. O. El Medhi, "Identification of timed stochastic Petri net models with normal distributions of firing periods," in *IFAC Proceedings Volumes (IFAC-PapersOnline)*, 2009, vol. 13, no. PART 1, pp. 948–953.
- [29] M. E. Meda-Campaña and S. Medina-Vazquez, "Synthesis of timed Petri net models for on-line identification of Discrete Event Systems," in *IEEE International Conference on Control and Automation, ICCA*, 2011, pp. 1201–1206.
- [30] F. Basile and L. Ferrara, "Identification of timed input/output relationships for industrial automation systems using timed interpreted petri nets," in *Conference Proceedings - IEEE International Conference on Systems, Man and Cybernetics*, 2019, vol. 2019-October, pp. 1831–1837.
- [31] S. Schneider, L. Litz, and J.-J. Lesage, "Determination of timed transitions in identified discrete-event models for fault detection," in *2012 IEEE 51st IEEE Conference on Decision and Control (CDC)*, 2012, pp. 5816–5821.
- [32] D. Lefebvre, S. Rachidi, E. Leclercq, and Y. Pigne, "Temporal fault diagnosis for k-bounded non-Markovian SPN," in *2018 5th International Conference on Control, Decision and Information Technologies (CoDIT)*, 2018, pp. 271–276.
- [33] R. Ammour, E. Leclercq, E. Sanlaville, and D. Lefebvre, "A Comparative Study of Fault Prognosis Approaches for Timed Stochastic Discrete Event Systems," *IFAC-PapersOnLine*, vol. 50, no. 1, pp. 6807–6812, Jul. 2017.
- [34] J. W. Vásquez Capacho, C. G. Perez Zuñiga, Y. A. Muñoz Maldonado, and A. Ospino Castro, "Simultaneous occurrences and false-positives analysis in discrete event dynamic systems," *J. Comput. Sci.*, vol. 44, p. 101162, Jul. 2020.
- [35] Y. Liu, S. Shu, F. Lin, Q. Chen, C. Liu, and F. Lian, "Online prognosis of stochastic

discrete event systems with guaranteed performance bound,” *Automatica*, vol. 156, p. 111139, Oct. 2023.

- [36] M. Ortiz-Barrios, S. Arias-Fonseca, A. Ishizaka, M. Barbati, B. Avendaño-Collante, and E. Navarro-Jiménez, “Artificial intelligence and discrete-event simulation for capacity management of intensive care units during the Covid-19 pandemic: A case study,” *J. Bus. Res.*, vol. 160, p. 113806, May 2023.
- [37] D. M. Muñoz, A. Correcher, E. García, and F. Morant, “Stochastic des fault diagnosis with coloured interpreted petri nets,” *Math. Probl. Eng.*, vol. 2015, 2015.
- [38] F. Basile and L. Ferrara, “Residuals-based fault diagnosis of industrial automation systems using timed and untimed Interpreted Petri nets,” *Control Eng. Pract.*, vol. 129, p. 105361, Dec. 2022.
- [39] F. K. Hoehler, “Bias and prevalence effects on kappa viewed in terms of sensitivity and specificity,” *J. Clin. Epidemiol.*, vol. 53, no. 5, pp. 499–503, May 2000.
- [40] M. Ohsaki, P. Wang, K. Matsuda, S. Katagiri, H. Watanabe, and A. Ralescu, “Confusion-matrix-based kernel logistic regression for imbalanced data classification,” *IEEE Trans. Knowl. Data Eng.*, vol. 29, no. 9, pp. 1806–1819, Sep. 2017.
- [41] R. Santillán-Mosquera and M. Muñoz-Añasco, “Identification of unobservable behavior in stochastic discrete event systems with a low number of sensors,” *MethodsX*, vol. 11, p. 102316, Dec. 2023.

9 Anexos

Anexo 1. Datos generados del caso de estudio 1

Tiempo	Señal 1	Señal 2	Señal 3	Secuencia de evento nominal	Secuencia de tiempo nominal
2,370	0	0	1	1	2,370
8,346	0	1	1	3	5,975
11,209	0	1	0	2	2,863
14,389	1	0	0	4	3,180
16,875	0	0	1	1	2,486
21,276	0	1	1	3	4,400
25,830	0	1	0	2	4,555
28,460	1	0	0	4	2,630
30,749	0	0	1	1	2,289
35,887	0	1	0	2	5,137
40,314	0	1	1	3	4,427
41,362	1	0	0	4	1,048
43,405	0	0	1	1	2,043
47,838	0	1	1	3	4,433
54,257	0	1	0	2	6,419
56,799	1	0	0	4	2,542
60,288	0	0	1	1	3,489
63,837	0	1	1	3	3,548
68,161	0	1	0	2	4,325
70,659	1	0	0	4	2,497
72,686	0	0	1	1	2,028
76,159	0	1	0	2	3,472
79,993	0	1	1	3	3,834
82,908	1	0	0	4	2,916
84,348	0	0	1	1	1,440
87,217	0	1	0	2	2,869
90,285	0	1	1	3	3,067
91,898	1	0	0	4	1,613
94,639	0	0	1	1	2,741
98,945	0	1	1	3	4,307
103,874	0	1	0	2	4,929
107,173	1	0	0	4	3,299
110,101	0	0	1	1	2,928
114,968	0	1	1	3	4,866
117,408	0	1	0	2	2,440
120,840	1	0	0	4	3,432
123,127	0	0	1	1	2,288
126,846	0	1	1	3	3,718
131,003	0	1	0	2	4,158
134,217	1	0	0	4	3,214
137,654	0	0	1	1	3,436
143,876	0	1	0	2	6,222
148,271	0	1	1	3	4,395
150,851	1	0	0	4	2,581

Tiempo	Señal 1	Señal 2	Señal 3	Secuencia de evento nominal	Secuencia de tiempo nominal
153,269	0	0	1	1	2,418
158,214	0	1	1	3	4,945
162,048	0	1	0	2	3,834
164,325	1	0	0	4	2,277
167,419	0	0	1	1	3,094
171,209	0	1	1	3	3,790
175,494	0	1	0	2	4,285
177,239	1	0	0	4	1,744
180,318	0	0	1	1	3,079
185,276	0	1	0	2	4,958
191,001	0	1	1	3	5,725
192,439	1	0	0	4	1,438
195,692	0	0	1	1	3,253
201,824	0	1	1	3	6,133
205,317	0	1	0	2	3,492
208,145	1	0	0	4	2,829
210,112	0	0	1	1	1,967
212,751	0	1	0	2	2,638
217,365	0	1	1	3	4,614
219,112	1	0	0	4	1,747
222,275	0	0	1	1	3,163
225,818	0	1	0	2	3,543
230,374	0	1	1	3	4,557
232,477	1	0	0	4	2,103
234,489	0	0	1	1	2,012
237,660	0	1	1	3	3,171
241,059	0	1	0	2	3,398
243,429	1	0	0	4	2,370
245,820	0	0	1	1	2,391
249,958	0	1	1	3	4,138
253,503	0	1	0	2	3,545
255,193	1	0	0	4	1,690
257,598	0	0	1	1	2,405
263,682	0	1	1	3	6,084
268,417	0	1	0	2	4,735
271,032	1	0	0	4	2,615
273,682	0	0	1	1	2,650
278,733	0	1	1	3	5,051
282,507	0	1	0	2	3,774
285,421	1	0	0	4	2,914
287,420	0	0	1	1	1,999
292,938	0	1	0	2	5,518
298,621	0	1	1	3	5,683
302,356	1	0	0	4	3,735
304,738	0	0	1	1	2,382
309,939	0	1	1	3	5,202
314,659	0	1	0	2	4,720
316,553	1	0	0	4	1,894
319,607	0	0	1	1	3,054
324,332	0	1	1	3	4,725
329,823	0	1	0	2	5,491

Tiempo	Señal 1	Señal 2	Señal 3	Secuencia de evento nominal	Secuencia de tiempo nominal
333,299	1	0	0	4	3,477
335,782	0	0	1	1	2,483
339,524	0	1	1	3	3,742
343,830	0	1	0	2	4,306
346,280	1	0	0	4	2,450
349,872	0	0	1	1	3,592
355,057	0	1	1	3	5,185
359,356	0	1	0	2	4,299
361,947	1	0	0	4	2,591
364,430	0	0	1	1	2,483
368,782	0	1	1	3	4,351
373,832	0	1	0	2	5,050
375,326	1	0	0	4	1,494
377,612	0	0	1	1	2,286
380,540	0	1	0	2	2,927
384,378	0	1	1	3	3,838
387,702	1	0	0	4	3,324
391,077	0	0	1	1	3,375
396,893	0	1	1	3	5,816
401,150	0	1	0	2	4,257
404,002	1	0	0	4	2,852
406,230	0	0	1	1	2,228
410,810	0	1	0	2	4,580
416,262	0	1	1	3	5,453
418,709	1	0	0	4	2,446
420,402	0	0	1	1	1,693
425,783	0	1	1	3	5,381
431,120	0	1	0	2	5,337
433,016	1	0	0	4	1,895
435,883	0	0	1	1	2,868
439,269	0	1	0	2	3,386
443,611	0	1	1	3	4,342
445,840	1	0	0	4	2,229
448,676	0	0	1	1	2,836
453,067	0	1	0	2	4,391
458,754	0	1	1	3	5,687
461,545	1	0	0	4	2,791
464,045	0	0	1	1	2,500
468,917	0	1	0	2	4,872
473,648	0	1	1	3	4,731
476,578	1	0	0	4	2,930
479,266	0	0	1	1	2,688
483,167	0	1	0	2	3,901
488,394	0	1	1	3	5,228
491,048	1	0	0	4	2,654
492,955	0	0	1	1	1,907
497,542	0	1	1	3	4,587
501,327	0	1	0	2	3,785
504,639	1	0	0	4	3,312
507,124	0	0	1	1	2,485
512,120	0	1	1	3	4,996

Tiempo	Señal 1	Señal 2	Señal 3	Secuencia de evento nominal	Secuencia de tiempo nominal
516,195	0	1	0	2	4,075
518,605	1	0	0	4	2,410
521,105	0	0	1	1	2,501
525,875	0	1	0	2	4,770
529,234	0	1	1	3	3,358
530,882	1	0	0	4	1,648

Anexo 2. Datos generados del caso de estudio 2

Tiempo	Señal 1	Señal 2	Señal 3	Señal 4	Secuencia de evento nominal	Secuencia de tiempo nominal
59,276	0	0	0	1	1	59,276
62,437	0	0	1	0	2	3,161
63,437	0	0	1	1	3	1,000
64,437	0	1	0	1	5	1,000
66,615	0	1	1	1	7	2,178
69,434	1	0	0	1	9	2,819
70,434	0	0	1	1	3	1,000
71,434	0	1	0	0	4	1,000
73,519	0	1	1	0	6	2,085
76,364	1	0	0	0	8	2,845
77,364	0	0	1	1	3	1,000
78,364	0	1	0	1	5	1,000
80,506	0	1	1	1	7	2,142
83,376	1	0	0	1	9	2,871
84,376	0	0	1	1	3	1,000
85,376	0	1	0	1	5	1,000
87,504	0	1	1	1	7	2,128
90,328	1	0	0	1	9	2,823
91,328	0	0	1	1	3	1,000
92,328	0	1	0	0	4	1,000
94,486	0	1	1	0	6	2,158
97,294	1	0	0	0	8	2,809
98,294	0	0	1	1	3	1,000
99,294	0	1	0	1	5	1,000
101,376	0	1	1	1	7	2,081
104,218	1	0	0	1	9	2,842
105,218	0	0	1	1	3	1,000
106,218	0	1	0	1	5	1,000
108,374	0	1	1	1	7	2,156
111,230	1	0	0	1	9	2,856
112,230	0	0	1	1	3	1,000
113,230	0	1	0	0	4	1,000
115,422	0	1	1	0	6	2,192
118,221	1	0	0	0	8	2,799
119,221	0	0	1	1	3	1,000
120,221	0	1	0	1	5	1,000
122,353	0	1	1	1	7	2,132
125,184	1	0	0	1	9	2,831

Tiempo	Señal 1	Señal 2	Señal 3	Señal 4	Secuencia de evento nominal	Secuencia de tiempo nominal
126,184	0	0	1	1	3	1,000
127,184	0	1	0	0	4	1,000
129,371	0	1	1	0	6	2,187
132,162	1	0	0	0	8	2,791
133,162	0	0	1	1	3	1,000
134,162	0	1	0	0	4	1,000
136,266	0	1	1	0	6	2,103
139,127	1	0	0	0	8	2,862
140,127	0	0	1	1	3	1,000
141,127	0	1	0	1	5	1,000
143,230	0	1	1	1	7	2,103
146,139	1	0	0	1	9	2,909
147,139	0	0	1	1	3	1,000
148,139	0	1	0	0	4	1,000
150,253	0	1	1	0	6	2,114
153,084	1	0	0	0	8	2,831
154,084	0	0	1	1	3	1,000
155,084	0	1	0	1	5	1,000
157,189	0	1	1	1	7	2,104
160,055	1	0	0	1	9	2,866
161,055	0	0	1	1	3	1,000
162,055	0	1	0	0	4	1,000
164,167	0	1	1	0	6	2,112
167,075	1	0	0	0	8	2,908
168,075	0	0	1	1	3	1,000
169,075	0	1	0	1	5	1,000
171,217	0	1	1	1	7	2,142
174,034	1	0	0	1	9	2,817
175,034	0	0	1	1	3	1,000
176,034	0	1	0	1	5	1,000
178,197	0	1	1	1	7	2,163
181,061	1	0	0	1	9	2,864
182,061	0	0	1	1	3	1,000
183,061	0	1	0	0	4	1,000
185,144	0	1	1	0	6	2,083
187,969	1	0	0	0	8	2,826
188,969	0	0	1	1	3	1,000
189,969	0	1	0	1	5	1,000
192,138	0	1	1	1	7	2,168
195,032	1	0	0	1	9	2,895
196,032	0	0	1	1	3	1,000
197,032	0	1	0	1	5	1,000
199,206	0	1	1	1	7	2,174
202,044	1	0	0	1	9	2,837
203,044	0	0	1	1	3	1,000
204,044	0	1	0	1	5	1,000
206,195	0	1	1	1	7	2,151
209,027	1	0	0	1	9	2,833
210,027	0	0	1	1	3	1,000
211,027	0	1	0	0	4	1,000
213,185	0	1	1	0	6	2,158

Tiempo	Señal 1	Señal 2	Señal 3	Señal 4	Secuencia de evento nominal	Secuencia de tiempo nominal
216,032	1	0	0	0	8	2,847
217,032	0	0	1	1	3	1,000
218,032	0	1	0	1	5	1,000
220,192	0	1	1	1	7	2,160
223,081	1	0	0	1	9	2,889
224,081	0	0	1	1	3	1,000
225,081	0	1	0	0	4	1,000
227,266	0	1	1	0	6	2,185
230,072	1	0	0	0	8	2,806
231,072	0	0	1	1	3	1,000
232,072	0	1	0	0	4	1,000
234,230	0	1	1	0	6	2,158
237,039	1	0	0	0	8	2,809
238,039	0	0	1	1	3	1,000
239,039	0	1	0	0	4	1,000
241,231	0	1	1	0	6	2,192
244,112	1	0	0	0	8	2,880
245,112	0	0	1	1	3	1,000
246,112	0	1	0	1	5	1,000
248,203	0	1	1	1	7	2,092
251,050	1	0	0	1	9	2,846
252,050	0	0	1	1	3	1,000
253,050	0	1	0	1	5	1,000
255,147	0	1	1	1	7	2,097
258,036	1	0	0	1	9	2,889
259,036	0	0	1	1	3	1,000
260,036	0	1	0	1	5	1,000
262,218	0	1	1	1	7	2,182
265,075	1	0	0	1	9	2,857
266,075	0	0	1	1	3	1,000
267,075	0	1	0	0	4	1,000
269,173	0	1	1	0	6	2,098
272,057	1	0	0	0	8	2,884
273,057	0	0	1	1	3	1,000
274,057	0	1	0	1	5	1,000
276,228	0	1	1	1	7	2,172
279,048	1	0	0	1	9	2,820
280,048	0	0	1	1	3	1,000
281,048	0	1	0	0	4	1,000
283,209	0	1	1	0	6	2,161
286,036	1	0	0	0	8	2,827
287,036	0	0	1	1	3	1,000
288,036	0	1	0	0	4	1,000
290,149	0	1	1	0	6	2,113
292,964	1	0	0	0	8	2,815
293,964	0	0	1	1	3	1,000
294,964	0	1	0	0	4	1,000
297,143	0	1	1	0	6	2,179
299,969	1	0	0	0	8	2,826
300,969	0	0	1	1	3	1,000
301,969	0	1	0	0	4	1,000

Tiempo	Señal 1	Señal 2	Señal 3	Señal 4	Secuencia de evento nominal	Secuencia de tiempo nominal
304,149	0	1	1	0	6	2,180
306,956	1	0	0	0	8	2,807
307,956	0	0	1	1	3	1,000
308,956	0	1	0	1	5	1,000
311,050	0	1	1	1	7	2,094
313,944	1	0	0	1	9	2,894
314,944	0	0	1	1	3	1,000
315,944	0	1	0	0	4	1,000
318,026	0	1	1	0	6	2,082
320,874	1	0	0	0	8	2,848

Anexo 3. Datos generados del caso de estudio 3

Tiempo	Señal 1	Señal 2	Señal 3	Secuencia de evento nominal	Secuencia de tiempo nominal
2,189	1	0	0	4	2,189
3,202	0	1	1	3	1,012
6,515	1	1	0	6	3,314
10,194	1	1	1	7	3,679
13,456	1	0	0	4	3,262
17,130	1	0	1	5	3,674
18,932	0	0	1	1	1,802
21,346	0	1	0	2	2,414
23,256	0	1	1	3	1,909
26,262	1	1	0	6	3,006
29,204	1	1	1	7	2,942
31,768	0	0	1	1	2,563
35,335	0	1	0	2	3,567
36,424	0	1	1	3	1,090
39,963	1	1	0	6	3,538
41,285	1	1	1	7	1,322
43,636	0	0	1	1	2,351
46,599	0	1	0	2	2,963
49,228	1	0	1	5	2,629
51,245	1	0	0	4	2,017
54,056	0	1	1	3	2,811
57,116	1	1	0	6	3,060
58,370	1	1	1	7	1,254
61,163	1	0	0	4	2,793
64,224	1	0	1	5	3,062
66,010	0	0	1	1	1,786
68,969	0	1	0	2	2,959
71,955	1	0	1	5	2,986
74,255	1	0	0	4	2,300
76,032	0	1	1	3	1,777
79,434	1	1	0	6	3,402
83,281	1	1	1	7	3,847
85,565	1	0	0	4	2,284
88,661	1	0	1	5	3,096

Tiempo	Señal 1	Señal 2	Señal 3	Secuencia de evento nominal	Secuencia de tiempo nominal
92,278	1	0	0	4	3,617
94,683	1	0	1	5	2,405
98,016	1	0	0	4	3,332
100,016	1	0	1	5	2,000
101,558	0	0	1	1	1,542
105,370	0	1	0	2	3,812
108,509	1	0	1	5	3,140
111,438	0	0	1	1	2,928
113,485	0	1	0	2	2,048
113,647	0	1	1	3	0,162
117,598	1	1	0	6	3,951
119,647	1	1	1	7	2,049
121,853	1	0	0	4	2,206
124,558	1	0	1	5	2,705
128,035	1	0	0	4	3,477
131,899	1	0	1	5	3,864
133,093	0	0	1	1	1,193
136,472	0	1	0	2	3,379
137,473	0	1	1	3	1,001
141,272	1	1	0	6	3,800
144,338	1	1	1	7	3,066
147,554	1	0	0	4	3,216
150,449	0	1	1	3	2,896
153,758	1	1	0	6	3,309
155,617	1	1	1	7	1,859
156,988	0	0	1	1	1,371
160,445	0	1	0	2	3,457
163,074	1	0	1	5	2,629
165,543	1	0	0	4	2,469
167,768	0	1	1	3	2,225
170,835	1	1	0	6	3,067
174,274	1	1	1	7	3,438
177,288	1	0	0	4	3,015
178,772	0	1	1	3	1,484
182,071	1	1	0	6	3,299
186,457	1	1	1	7	4,386
189,976	1	0	0	4	3,519
192,006	1	0	1	5	2,030
193,657	0	0	1	1	1,652
197,638	0	1	0	2	3,981
199,998	1	0	1	5	2,361
203,643	1	0	0	4	3,645
206,591	0	1	1	3	2,948
209,693	1	1	0	6	3,101
213,822	1	1	1	7	4,129
216,809	0	0	1	1	2,988
220,543	0	1	0	2	3,733
221,406	0	1	1	3	0,863
224,997	1	1	0	6	3,592
226,442	1	1	1	7	1,444
229,356	1	0	0	4	2,914

Tiempo	Señal 1	Señal 2	Señal 3	Secuencia de evento nominal	Secuencia de tiempo nominal
232,115	1	0	1	5	2,759
234,874	0	0	1	1	2,760
237,215	0	1	0	2	2,341
238,085	0	1	1	3	0,870
241,476	1	1	0	6	3,391
243,184	1	1	1	7	1,708
246,141	0	0	1	1	2,957
248,141	0	1	0	2	2,001
250,173	0	1	1	3	2,031
253,207	1	1	0	6	3,034
254,563	1	1	1	7	1,356
257,395	0	0	1	1	2,831
260,783	0	1	0	2	3,388
262,188	0	1	1	3	1,405
265,535	1	1	0	6	3,347
268,931	1	1	1	7	3,396
271,388	0	0	1	1	2,457
274,906	0	1	0	2	3,519
278,274	1	0	1	5	3,368
281,355	1	0	0	4	3,081
284,618	1	0	1	5	3,263
287,201	1	0	0	4	2,583
289,656	1	0	1	5	2,455
293,524	1	0	0	4	3,868
295,583	0	1	1	3	2,059
299,085	1	1	0	6	3,502
301,385	1	1	1	7	2,300
304,131	1	0	0	4	2,745
306,798	1	0	1	5	2,667
308,895	0	0	1	1	2,097
312,005	0	1	0	2	3,111
315,096	1	0	1	5	3,090
318,371	1	0	0	4	3,275
320,559	1	0	1	5	2,189
322,046	0	0	1	1	1,487
325,222	0	1	0	2	3,176
328,847	1	0	1	5	3,625
332,190	1	0	0	4	3,343
332,592	0	1	1	3	0,402
336,202	1	1	0	6	3,610
338,247	1	1	1	7	2,045
341,382	1	0	0	4	3,135
344,088	1	0	1	5	2,706
345,591	0	0	1	1	1,503
347,860	0	1	0	2	2,269
350,380	1	0	1	5	2,520
353,130	0	0	1	1	2,750
356,256	0	1	0	2	3,126
358,794	0	1	1	3	2,538
362,069	1	1	0	6	3,275
363,426	1	1	1	7	1,357

Tiempo	Señal 1	Señal 2	Señal 3	Secuencia de evento nominal	Secuencia de tiempo nominal
365,882	0	0	1	1	2,456
368,903	0	1	0	2	3,021
370,951	1	0	1	5	2,048
373,399	1	0	0	4	2,448
375,077	0	1	1	3	1,678
378,314	1	1	0	6	3,237
381,783	1	1	1	7	3,469
385,130	1	0	0	4	3,347
387,644	0	1	1	3	2,514
391,196	1	1	0	6	3,552
392,316	1	1	1	7	1,120
394,884	1	0	0	4	2,568
396,629	0	1	1	3	1,744
399,765	1	1	0	6	3,136
404,599	1	1	1	7	4,834

Anexo 4. Datos generados del modelo con comportamiento no observable