

Metodología de implementación en PLC de un sistema de diagnóstico automático para bandas transportadoras basado en el algoritmo LAMDA

Juan. C. Serna.

Departamento de electrónica, Universidad de Antioquia
Medellín, Antioquia, Colombia

Víctor.M. Gómez

Departamento de electrónica, Tecnológico Pascual Bravo I.U.
Medellín, Antioquia, Colombia

J. S. Bedoya

Departamento de electrónica, Universidad de Antioquia
Medellín, Antioquia, Colombia

RESUMEN

Se presenta una metodología para implementar en PLCs de gama baja, un sistema de diagnóstico automático de procesos basado en el algoritmo de aprendizaje para análisis de datos multivariable (LAMDA). La metodología es aplicada a la supervisión de un sistema de banda transportadora, en el que se emplean sólo tres descriptores del proceso; asociados a dos sensores de posición ubicados a lo largo de la banda y la velocidad de la misma. Se consideran los estados de falla del proceso: producción discontinua, paro de producción y atasco, además se tuvieron en cuenta los estados apagado, funcionamiento normal y NIC (*Non Informative Class*).

Se han utilizado la media y la desviación estandar como parametros representativos del estado de sistema.

Para validar el sistema de diagnóstico, se han realizado fallos simultaneos en el proceso de la banda. Los resultados de validación del sistema de diagnóstico muestran un excelente desempeño con un porcentaje de aciertos del 73% en donde se consideran tanto fallas simultáneas como una falla a la vez.

Palabras clave: Clustering difuso, Diagnóstico automatico de fallas en procesos, automatización industrial, algoritmo LAMDA, Reconocimiento de patrones.

1. INTRODUCCIÓN

Garantizar el cumplimiento de los compromisos, proteger los recursos físicos y humanos, conlleva a monitorear los sistemas para detectar y diagnosticar las anomalías en los procesos automáticos de producción. Por lo anterior, es importante identificar los estados funcionales asociados a los procesos, no sólo para corregir fallos sino también para predecirlos y evitar paros innecesarios de la planta.

Actualmente en sistemas de transporte de objetos, la supervisión depende en gran medida del humano y está ligada a la capacidad de un operario de identificar los estados de funcionamiento, las alarmas y fallos. En un sistema de supervisión basado únicamente en operarios humanos sin métodos de apoyo para monitoreo, se pueden presentar demoras en identificar un estado de fallo; debido a la fatiga que puede presentar una persona al tener que analizar constantemente un gran número de variables [1].

El diagnóstico de las fallas de la maquinaria es un procedimiento de correlación de la información obtenida en la medición, con los fallos de la máquina. Este proceso es llamado reconocimiento de patrones [2].

Existe interés permanente de explorar nuevas herramientas que permitan mejorar la eficiencia en la extracción de información del estado de las máquinas y realizar un diagnóstico automático de los procesos. En este sentido las técnicas basadas en inteligencia artificial son muy empleadas, pero son pocos los reportes en la literatura sobre la implementación en equipos industriales de uso común como los controladores lógicos programables de bajo costo (PLC).

Los sistemas de supervisión donde se hace análisis en línea de la correlación de múltiples variables son costosos; además, se basan únicamente en el análisis de umbrales para cada variable; y la identificación de estados funcionales basándose sólo en umbrales no siempre da buenos resultados [1].

Una de las herramientas para realizar la correlación de las señales provenientes de las variables descriptivas de los procesos, es el agrupamiento (Clustering); en función de un criterio de similitud. El Clustering puede ser de tipo concreto o difuso; la gran diferencia radica en que al realizarse por medio de la lógica difusa permite asignar, para un vector de valores tomados del proceso en el tiempo t , grados de pertenencia a cada una de las clases (estados funcionales del proceso) que se contemplan y no asociar de manera absoluta una clase.

Un algoritmo de Clustering que ha presentado buenos resultados en aplicaciones de supervisión y que tiene un costo computacional mínimo es el algoritmo LAMDA (Learning Algorithm for Multivariate Data Analysis). La ventaja de tener un tiempo corto de cálculo lo hace atractivo para realizar aplicaciones en línea a través de implementación en un Controlador lógico programable (PLC, por sus siglas en inglés).

Sistemas de supervisión usando Clustering difuso, específicamente con el algoritmo LAMDA, han sido implementados en trabajos anteriores en tiempo real usando tarjetas de adquisición de datos que llevan señales al computador y permiten su manipulación; como es el caso del monitoreo de plantas de tratamiento de agua [3] y de calderas [4]. La etapa de análisis de datos se realiza mediante software especializado en dicho algoritmo. Estos programas son útiles para llevar a cabo las tareas de supervisión pero presentan limitaciones técnicas, tales como susceptibilidad al ruido electromagnético, y falta de flexibilidad; que los hacen poco usados en la industria. Teniendo en cuenta que en el sector industrial hay un alto uso de PLCs, se ve la importancia de desarrollar un sistema para supervisión de procesos que esté implementado en dichos dispositivos.

2. CONCEPTOS FUNDAMENTALES

La lógica difusa es una metodología capaz de trabajar con entradas de información imprecisa y/o incompleta, con algún grado de incertidumbre. En términos generales esta lógica busca emular la forma en la que los seres humanos toman decisiones para llevarla a aplicaciones de hardware, software o incluso combinación de ambas [5].

Los sistemas basados en lógica difusa combinan variables de entrada, definidas en términos de conjuntos difusos, por medio de grupos de reglas que producen uno o varios valores de salida.

Las características más atractivas de la lógica difusa son su flexibilidad, su tolerancia con la imprecisión, su capacidad para modelar problemas no lineales y su base en el lenguaje natural.

Métodos de diagnóstico.

Los métodos de diagnóstico se pueden agrupar en tres grupos de acuerdo a la naturaleza de los datos. La organización de estos métodos se presenta en la figura 1.

La estrategia más simple de diagnóstico es el monitoreo de umbrales relacionados con las señales más representativas del proceso. La configuración inadecuada de estos umbrales puede llevar a la aparición de alarmas repetitivas, o no recibir alarmas cuando se está presentando un fallo del sistema.

Algoritmo LAMDA.

Las variables relacionadas con un proceso, no son independientes; por lo tanto, los umbrales de funcionamiento normal o de fallo deben estar vinculados por estas mismas relaciones. Aparece

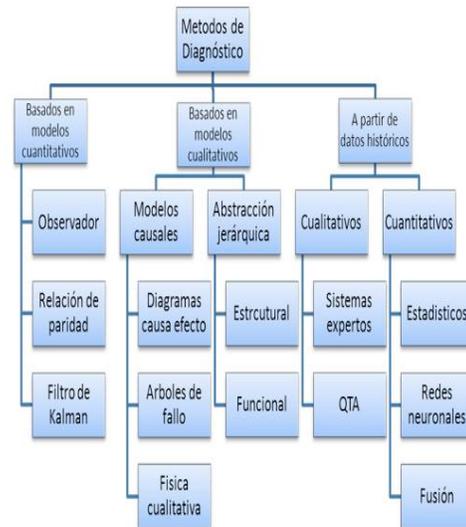


Figura 1 Organización de métodos de diagnóstico.

entonces la necesidad de métodos de diagnóstico capaces de analizar de manera conjunta la información entregada por múltiples variables y no de forma independiente.

El algoritmo LAMDA es una metodología de agrupamiento basada en la adecuación de los individuos a las clases, usando conceptos de la teoría de posibilidades [6].

Con éste método se obtienen resultados comparables a los de otras técnicas como las redes neuronales y clasificadores difusos basados en distancia [3]. LAMDA posee la ventaja de poder trabajar con datos cualitativos y cuantitativos simultáneamente, además de realizar clasificaciones no supervisadas, sin definir previamente el número de clases. Las clases se van generando progresivamente y un individuo que presente características muy diferentes a las de las clases actuales genera una nueva clase [3]. También se puede hacer clasificación supervisada, o clasificación en línea de nuevos individuos para evaluar el grado de pertenencia a las clases ya establecidas. Otra gran ventaja que presenta este algoritmo es que no requiere iteraciones para el entrenamiento y el costo computacional es muy bajo comparado con los algoritmos basados en distancia [7].

La contribución de cada uno de los atributos o descriptores del individuo, al grado de pertenencia a una clase es lo que se llama adecuación marginal (MAD, Marginal Adequacy Degree). Estas adecuaciones marginales se combinan mediante operadores “Difusos Mixtos”, para finalmente encontrar el grado de adecuación global del individuo a cada una de las clases (GAD, Global Adequacy Degree) [2].

La figura 2 muestra el principio general de funcionamiento del método LAMDA, donde se observa un individuo (objeto X) a la entrada con 4 descriptores y 2 clases para analizar su adecuación.

Primero debe calcularse el Grado de Adecuación Marginal (por sus siglas en inglés, MAD) para cada

descriptor y cada clase; para luego obtener el Grado de Adecuación Global (por sus siglas en inglés, GAD). La asignación de la clase al individuo se hace mediante el máximo de los GAD; es decir, el individuo es ubicado en la clase que muestre mayor grado de adecuación global o mayor grado de pertenencia, esto sin perder la información de la pertenencia a otras clases.

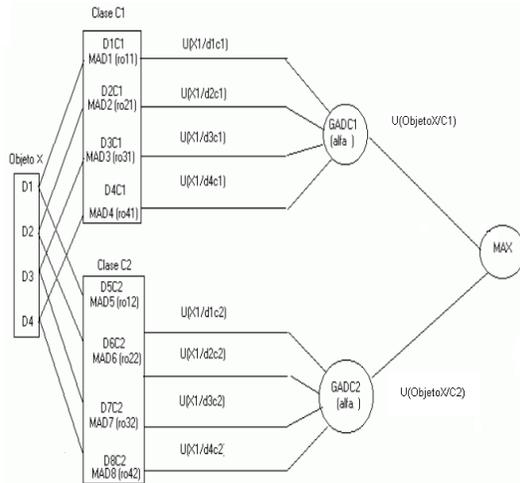


Figura 2 Principio general de funcionamiento del método LAMDA.

A manera de ejemplo se puede decir que para el caso mostrado en la figura 3 se tendrían 8 MADs y 2 GADs.

El aprendizaje consiste en encontrar parámetros que definan cada uno de los descriptores de las clases. El tipo de parámetros y la forma de encontrarlos depende de si se trabaja con descriptores cualitativos o cuantitativos, y la forma de calcularlos depende de si el aprendizaje es supervisado o no; es decir, si se conoce el número de clases previamente y que individuos pertenecen a ella o no.

Cuando se realiza aprendizaje supervisado, se cuenta con un grupo de individuos, se conoce a que clase pertenecen y se obtienen los parámetros que definen cada clase. Si el aprendizaje es no supervisado, estos parámetros se calculan progresivamente a medida que cada objeto se analiza; ya sea que este se incluya en una clase o genere una nueva.

Existe una clase de no información (NIC=Non Informative Class), la cual determina el umbral mínimo de adecuación global que debe tener un individuo para que pertenezca a alguna clase. La NIC funciona de la misma manera que las demás clases a diferencia que los parámetros que la caracterizan, hacen que todos los individuos tengan el mismo grado de pertenencia a la misma. Esta clase permite no incluir individuos poco representativos en las clases, pues se debe superar un umbral mínimo para la pertenencia a una clase.

El cálculo del grado de adecuación marginal, cuando se tienen individuos con descriptores cuantitativos; se hace mediante funciones donde se tienen en cuenta los

valores del individuo en cada descriptor. El aprendizaje consiste en encontrar parámetros específicos de estas funciones.

Al inicio del aprendizaje, cada valor, de cada descriptor dentro del individuo; debe ser normalizado. La normalización es de la forma:

$$x_j = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

Donde x_j corresponde al descriptor j -ésimo normalizado del individuo X , x_{\min} y x_{\max} corresponden al valor mínimo y máximo que tengan todos los individuos (tanto los de clasificación como de aprendizaje) en el descriptor j .

Existen varias funciones de tipo distribución probabilista para el cálculo de los MADs; entre ellas la binomial, binomial modificada y normal. Estas funciones permiten tener diferentes particiones, que pueden adecuarse a grupos de datos diferentes.

En este trabajo se ha usado la función normal (Gaussiana), mostrada en la ecuación 2.

$$MADx_{jk} = \frac{1}{\sigma_{kj}} e^{-\frac{1}{2} \frac{(X_j - \mu_{kj})^2}{\sigma_{kj}^2}} \quad (2)$$

Donde μ_{kj} y σ_{kj} son la media y desviación estándar del descriptor j para la clase k respectivamente.

El aprendizaje en modo supervisado consiste en el cálculo de estos dos valores (medias y desviaciones estándar para cada descriptor de cada clase), teniendo en cuenta que se conocen con anterioridad los datos y la clase a la cual pertenecen. En este caso los valores de la media y desviación estándar para la clase NIC son 0.5 y 0.25 respectivamente.

En aprendizaje no supervisado, los parámetros se actualizan con la ecuación 3 y 4 tomado de [3].

$$\mu_{kj}(t) = \mu_{kj}(t-1) + (x_j - \mu_{kj}(t-1)) / n^* \quad (3)$$

$$\sigma_{kj}^2(t) = \sigma_{kj}^2(t-1) + ((x_j - \mu_{kj}(t))^2 - \sigma_{kj}^2(t-1)) / n^* \quad (4)$$

Donde $n^* = n_0 + 1$

La creación de una nueva clase, depende de si un dato queda clasificado en la NIC. Los valores de la media y la desviación estándar de la nueva clase, dependerán de la media y la desviación estándar de la NIC y del valor en cada descriptor que tenga el dato clasificado en la NIC.

La figura 3 muestra un esquema que explica el procesamiento de los datos en la técnica LAMDA, tanto en aprendizaje como en prueba.

La forma general para el cálculo del GAD se presenta en la ecuación 5, donde α es el parámetro de exigencia.

$$GAD = \alpha (T - Norma) + (1 - \alpha)(S - Norma) \quad (5)$$

Para la S-Norma y la T-norma pueden elegirse máximo y mínimo o suma probabilística.

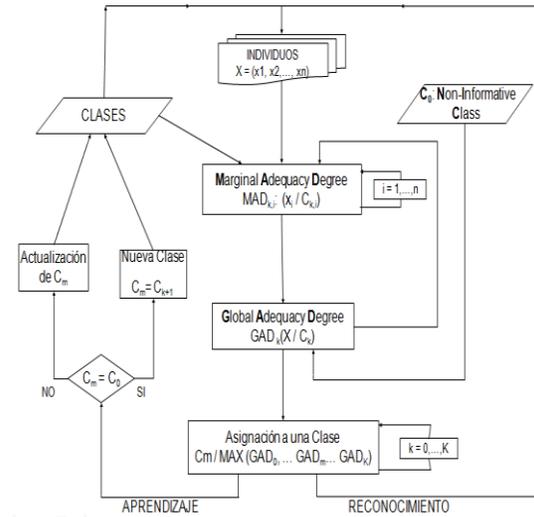


Figura 3 Procesamiento de datos técnica LAMDA.

3. DESCRIPCIÓN DEL SISTEMA DE BANDA TRANSPORTADORA

El equipo utilizado para la implementación del sistema de diagnóstico (*Hardware* y *Software*) se compone de los siguientes elementos:

- Banda transportadora
- Motor tipo jaula de ardilla
- Reductor ASSI
- Tablero de conexiones
- Variador de velocidad Altivar 58
- PLC Micro TSX – 3710
- Pantalla de explotación (HMI)
- Sensores de posición capacitivos
- Software PL7
- Software editor de pantallas de explotación
- Software SALSA
- Tarjeta de adquisición de datos.

La figura 4 muestra una foto del sistema de banda transportadora.

4. IMPLEMENTACIÓN DEL SISTEMA DE MONITOREO Y PRUEBAS DE VALIDACIÓN

Se instalaron dos sensores que miden un paso continuo de elementos, y un tercer descriptor que permite sensar la velocidad del motor. Inicialmente se inducen todos los estados de funcionamiento sobre la banda transportadora y se capturan las señales de los descriptores mediante una tarjeta de adquisición, esta información es consolidada

en una hoja de cálculo. En total son 700 datos, 100 para cada clase (excepto para la NIC).

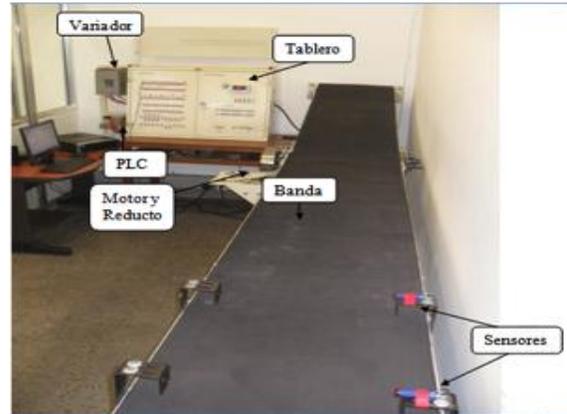


Figura 4 Sistema de banda transportadora

Sobre esta hoja se aplica el algoritmo LAMDA en modo de entrenamiento para obtener los parámetros representativos de cada clase (media y desviación estándar) y posteriormente se verifica la eficiencia de la clasificación en línea (modo reconocimiento), donde se prueban diferentes funciones para el cálculo del MAD y el GAD. De acuerdo a los resultados encontrados se escogen las funciones que ofrecen el mejor desempeño en clasificación. Para el cálculo del MAD y el GAD se utilizaron las funciones Gaussiana y probabilística respectivamente.

Se determinan las clases que se tendrán en cuenta (cada clase se asocia a un estado del sistema) y se estudian los rangos en los cuales los descriptores (variables medidas) entregan su información. La tabla 1 muestra los rangos reales de los descriptores y los asignados en el PLC.

Tabla 1 Rangos de los descriptores.

Descriptor	Rango(Real)	Rango (PLC)
Sensor 1	0 - 24 V	1 - 6
Sensor 2	0 - 24 V	1 - 6
Velocidad	0 - 62 HZ	0 - 10

Los sensores 1 y 2 sólo indican los estados de apagado (1) o encendido (6) sin depender uno del otro; mientras que el descriptor de la velocidad entrega mayor información y por eso su rango es un poco más amplio, dicha información está consignada en la Tabla 2.

Tabla 2 Rangos de velocidad

Velocidad	Rango real (HZ)	Rango PLC
Apagado (Velocidad cero)	0 - 3	0
Velocidad Baja	4 - 22.4	1 - 3
Velocidad Normal	24.9 - 42.2	4 - 6
Velocidad Alta	43.5 - 62	7 - 10

Las clases contempladas son:

- Apagado
- Normal
- Fallo sensor 1 (producción discontinua)
- Fallo sensor 2 (producción discontinua)
- Fallo ambos sensores (paro de producción)
- Velocidad baja
- Velocidad alta (atasque)

Sobre las funciones ya definidas, se realiza la búsqueda del valor del parámetro de exigencia alfa que permita al clasificador tener el mejor comportamiento. El valor del parámetro de exigencia seleccionado es de 0.976.

El algoritmo de clasificación LAMDA, con sus parámetros ya definidos es implementado en el PLC. Este entrega el resultado del diagnóstico en pantalla, donde se observa el estado actual del sistema e información adicional de utilidad para el diagnóstico. El pseudocódigo ejecutado por el PLC se muestra en la figura 5.

Una vez el sistema de monitoreo esta funcionando, es posible observar el estado funcional del sistema (actual), el estado de cada uno de los descriptores y una gráfica de velocidad contra tiempo.

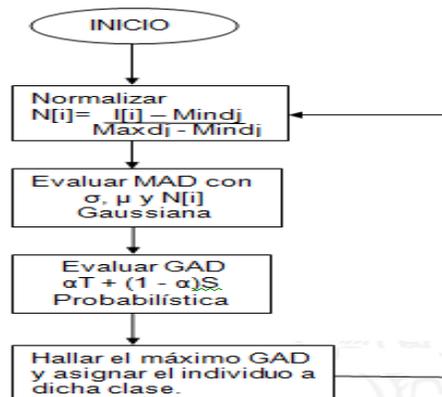


Figura 5 Algoritmo.

Las pruebas realizadas para el desempeño del sistema se dividieron en dos categorías. La primera corresponde a los casos que se contemplaron en el entrenamiento (es decir detectar aquellos estados con los que se entrenó el sistema) y la segunda a situaciones no contempladas, entre ellas fallos múltiples.

Para validar el funcionamiento del sistema de diagnóstico se indujeron 44 condiciones de funcionamiento, considerando: estados normales, estados de una falla y estados de fallas simultáneas.

5. RESULTADOS

El sistema de diagnóstico implementado en el PLC de gama baja permite acceder a la información de estado del sistema. La clasificación se hace en tiempo

real; es decir, cuando se produce un cambio en el proceso, el sistema requiere un tiempo inferior a dos segundos para cambiar su estado y la información en pantalla.

En cuanto a la implementación del algoritmo LAMDA en el PLC, se obtiene la clase o el estado funcional del proceso en línea, así como el acceso al valor de los GADs (grados de pertenencia) para cada una de las clases. Gracias a esta propiedad del algoritmo LAMDA se tiene una idea del siguiente estado con mayor posibilidad de presentarse. Si se hace un ordenamiento de los GADs de mayor a menor, se obtienen los posibles estados funcionales del sistema de banda transportadora, ordenados de acuerdo a su probabilidad de ocurrencia.

Al analizar los grados de pertenencia se encontró que la variación entre diferentes estados se presenta alrededor de cifras significativas que el PLC no considera; por lo tanto al convertirlos a enteros, sin superar el tamaño de memoria de la palabra, aparentemente resultan ser iguales. Esta irregularidad se presenta por la imposibilidad de comparar cifras decimales en el PLC y al tamaño reducido de memoria para una palabra.

Ante la aparición de un fallo simultáneo (casos no contemplados en el entrenamiento), el sistema de monitoreo entregó como resultado de clasificación el estado correspondiente a uno de los dos fallos que sucedieron en simultáneo (clase con mayor grado de pertenencia y NIC en segundo lugar); o en su defecto lo asignó a la clase NIC (con los dos componentes presentes en fallo en el segundo y tercer lugar).

La tabla 3 presenta el resultado de diagnóstico ante un fallo simultáneo donde aparece la NIC en segundo lugar. En la primera columna se presenta el estado de los tres descriptores; la segunda columna contiene el resultado de la clasificación, donde la primera fila corresponde a la clase donde el individuo es clasificado y las siguientes clases están ordenadas de acuerdo al valor del GAD, que se muestra en la tercera columna.

Tabla 3 Caso no entrenado.

Vector entrada (S1, S2, Vel)	Clasificación	GADs ordenados
0, 1, 2 Fallo múltiple Fallo sensor1 Velocidad baja	Vel. baja	0,0292094
	NIC	0,01920474
	Fallo S1	0,01439353
	Normal	0,00722167
	Fallo ambos	0,00722166
	Vel. alta	0,00717596
	Apagado	0,00717595
	Fallo S2	4,57E-05

En este caso, las fallas simultáneas inducidas son velocidad baja y fallo sensor 1 (estado de los descriptores: 0, 1, 2). El sistema de diagnóstico reconoce ambos fallos, pero da prioridad a la velocidad debido a que el descriptor asociado tiene un

mayor peso; es por eso que el estado del proceso aparece en la clase “velocidad baja”. La clase siguiente es la NIC, lo cual es acertado ya que es una situación no entrenada y debe tener un alto grado de pertenencia a la clase NIC; luego aparece la clase falla en el sensor 1 o producción discontinua. De ahí en adelante las clases se ordenan según su probabilidad de ocurrencia.

En varios casos analizados dentro de las pruebas de desempeño del sistema en los fallos múltiples, se observó que el descriptor analógico asociado a la velocidad, proporciona mayor información acerca del estado funcional del proceso y el método le da cierta prioridad en la clasificación.

La tabla 4 presenta el resultado de diagnóstico ante un fallo simultáneo donde aparece la NIC en primer lugar.

Tabla 4 Caso no entrenado, clase NIC.

Vector entrada (S1,S2, Vel)	Clasificación	GADs ordenados
0, 1, 7 Fallo múltiple Fallo sensor1 Velocidad alta	NIC	0,01920474
	Fallo S1	0,01649871
	Vel. alta	0,0113305
	Normal	0,00953352
	Fallo ambos	0,00953351
	Vel. baja	0,00717596
	Apagado	0,00717595
Fallo S2	0.00235756	

Este resultado es consecuente con lo descrito anteriormente.

Partiendo de la manera en que el PLC recibe los datos del descriptor analógico (velocidad), se requiere discretizar la variable y organizarla en tres intervalos (velocidad baja, velocidad normal y velocidad alta), como se muestra en la tabla 2. Al realizar esta aproximación el sistema de diagnóstico puede presentar confusiones en los estados de transición de velocidad, donde el resultado de la clasificación es NIC.

En general, se clasificaron 12 de los 44 casos de validación en la clase NIC, lo que representa un 27% del total de condiciones de validación consideradas. Este resultado aunque como ya se mencionó, no constituye un error de clasificación, es interpretado como un resultado no deseado; ya que no aporta información precisa del estado de funcionamiento del proceso. Por lo tanto se estima que el sistema obtuvo un 73% de aciertos en clasificación.

6. CONCLUSIONES Y PERSPECTIVAS

El diseño e implementación del sistema de diagnóstico basado en el algoritmo LAMDA para la banda transportadora presenta buenos resultados y puede ser usado en un ambiente industrial al ser implementado en PLCs de bajo costo.

Los resultados obtenidos en la validación proporcionan un desempeño óptimo y prometedor con posibilidad de implementación en otros procesos.

La principal restricción del PLC utilizado es la memoria de lectura/escritura para el continuo flujo y manipulación de datos, específicamente si se requiere hacer una organización de los grados de pertenencia para tener una aproximación a la predicción de estados futuros. Sin embargo las limitaciones de memoria, no afectan el tiempo de respuesta del sistema, pues el algoritmo LAMDA no requiere de una gran cantidad de cómputo. Aumentar la memoria del PLC y de visualización de la pantalla, posibilitaría entregar mayor información del proceso al operario; es decir, los grados de pertenencia a las demás clases, ordenados de mayor a menor. Esto permite tener mayor conocimiento en situaciones de fallos simultáneos.

El algoritmo LAMDA en sistemas de diagnóstico permite ser programado de manera general, donde el número de descriptores y de clases puede ser determinado por el usuario para la aplicación que requiera.

Las medias obtenidas en el entrenamiento son valores muy cercanos, lo que demuestra unos datos muy concentrados alrededor de la media con desviaciones estándar pequeñas. Esta situación es la causante de las confusiones en los puntos de transición de velocidad (baja – normal y normal - alta), ya que la media de la clase NIC es muy cercana a las demás. Aunque el método propone por defecto una media de 0.5 y desviación estándar de 0.25 para la clase NIC, un cambio en estos parámetros puede entregar mejores clasificaciones.

7. REFERENCIAS

- [1] J. GENTIL, *Supervision des procédés complexes*.
- [2] A. K. S. Jardine, D. Lin, y D. Banjevic, «A review on machinery diagnostics and prognostics implementing condition-based maintenance», *Mechanical Systems and Signal Processing*, vol. 20, n°. 7, pp. 1483 – 1510, 2006.
- [3] I. C., «Decision method for states validation in drinking water plant monitoring», 2007, pp. 363–368.
- [4] T. Kempowsky, A. Subias, y J. Aguilar-Martin, «Process situation assessment: From a fuzzy partition to a finite state machine», *Engineering Applications of Artificial Intelligence*, vol.19, n°.5, pp. 461–477, 2006.
- [5] J. H. Pardo Mayorga y A. Gauthier Sellier, «Clasificación y detección de fallas en Sistemas Dinámicos», *Revista de Ingeniería*, n°. 23, pp. 04–12, may 2006.
- [6] J. A. Martin y R. L. de Mantaras, «PROCESS OF CLASSIFICATION AND LEARNING THE MEANING OF LINGUISTIC DESCRIPTORS OF CONCEPTS.», pp. 165–175, 1982.
- [7] C. V. Isaza Narvaez, J. Aguilar-Martin, y M.-V. Le Lann, «Diagnostic par techniques d'apprentissage floues conception d'une méthode de validation et d'optimisation des partitions», INSA, Toulouse, 2007.