

# ESTIMACIÓN DE ESTADOS DE CONTROL EMPLEANDO DISEÑO EXPERIMENTAL Y REDES NEURONALES

J. A. Vázquez López  
Instituto Tecnológico de Celaya  
antoniov@itc.mx

I. López-Juárez  
Centro de Investigación y de Estudios Avanzados del IPN – Unidad Saltillo  
ismael.lopez@cinvestav.edu.mx

**Resumen**—Este artículo trata sobre la estimación de los estados de control (*estabilidad e inestabilidad*) en procesos industriales, lo cual se realiza mediante el reconocimiento de patrones especiales de variación. Estos patrones son representados típicamente en Gráficos de Control (GC) usados en los procesos de manufactura para vigilar el comportamiento de la calidad del producto. Se usa para este propósito la red neuronal Fuzzy-ARTMAP, cuyos parámetros de operación son seleccionados empleando técnicas de diseño experimental de tal forma de maximizar su eficiencia de reconocimiento. Los resultados obtenidos evidencian la utilidad del método. A diferencia de los GC, con este enfoque de estimación por medio del reconocimiento de patrones, se puede mantener el control estadístico del proceso en tiempo real, de forma sistemática, sin el supuesto de normalidad en los datos o de la independencia de los mismos, sin límites de control y sin requerimiento del juicio humano, además de poder procesar grandes cantidades de datos complejos en poco tiempo. El método de experimentación propuesto se probó mediante simulación usando el método de Monte Carlo en la generación de variables aleatorias del proceso y también utilizando datos de producción en planta, cuyos resultados se presentan en este artículo, lo que valida la aplicabilidad del método.

**Palabras clave:** Variable aleatoria, análisis estadístico, control estadístico de procesos, redes neuronales.

## I. INTRODUCCIÓN

La serie de datos numéricos obtenidos de un proceso de medición de la calidad de un producto manufacturado, genera, lo estadísticamente denominado, *variable aleatoria*. Toda variable aleatoria tiene un comportamiento estadístico que debe ser estudiado para poder generar esquemas de comprensión de la forma en que el sistema de manufactura opera. La media y la varianza de los datos son dos parámetros fundamentales en este propósito.

Los Gráficos de Control (GC) ayudan a comprender la forma y variación de los datos para explicar lo que está ocurriendo con la calidad del producto manufacturado. Mientras la calidad sea buena, la tendencia central de los datos y su dispersión serán las que permitan producir grandes cantidades de artículos dentro de especificaciones. Esto debería ser observado por los GC, sin embargo, presentan

desventajas, tales como incapacidad para identificar en tiempo real y de forma integral el tipo de patrón de variación presente en el proceso de manufactura. Por otro lado, estos suelen estar asociados a muestreos elevados cuando no hay simetría en la distribución de la variable observada<sup>1</sup>.

En un proceso de manufactura existen dos estados de control estadístico que son de *estabilidad e inestabilidad*. El primero se presenta cuando los valores de los parámetros esenciales de la característica de calidad se mantienen cercanos o iguales a los deseados y el estado de inestabilidad ocurre cuando se presentan causas de variación especial. Para una estimación del estado de control estadístico se desea detectar la variación total (VT) de los datos ocurrida en el proceso de manufactura y reflejada en la variable aleatoria X, la variación natural (VN) y la variación especial (VE). De este modo,  $VT = VN + VE$ , y si la variable aleatoria está en el rango desde donde  $VE \rightarrow 0$  hasta  $VE < VN$ , el proceso de manufactura operará de manera estable; por el contrario, si VE crece, de tal modo que  $VE \gg VN$ , habrá inestabilidad.

De forma general, un proceso de manufactura presenta variación ocasionada por la suma de los efectos de sus componentes, tales como maquinaria, equipo, mano de obra, medio ambiente, materiales, materia prima y método de trabajo. La VN es común en todo proceso, se mantiene relativamente baja y no afecta a la calidad del producto ya que solo pequeñas cantidades de unidades producidas estarán fuera de especificaciones. La VE también es ocasionada por los mismos elementos del proceso de manufactura, solo que su efecto en la mala calidad es significativo. En este sentido, en cierto momento de control del proceso, se debe tomar la decisión de si el proceso tiene solo VN o también VE. En este momento, se prueban las hipótesis de afirmar que el proceso no es estable cuando verdaderamente lo sea, o bien de aceptar que lo es cuando en realidad está fuera de control. Aceptar o rechazar las hipótesis conduce a errores estadísticos tipo I y II que están sujetos a error humano por interpretación.

Existen patrones de datos reconocidos en los GC, tales como el natural, cambios en el nivel de la media y tendencias entre otros. Estos denotan ambos estados de control del proceso en

<sup>1</sup> Teorema del límite central.

función de la combinación de sus características estadísticas. Esta investigación trata sobre la identificación de los momentos en que dichos patrones indican el estado de control del proceso ya sea de *estabilidad* o *inestabilidad* y de cómo éstos patrones son detectados sin usar GC empleando la Red Neuronal Artificial (RNA) Fuzzy-ARTMAP para su reconocimiento de forma automática y eficiente.

Después de una breve introducción del tema a tratar en la sección I, el artículo se organiza como sigue: En la sección II se presenta el trabajo relacionado a la investigación. En la sección III, se describen los patrones principales y sus características a identificar dentro de un proceso. Por otro lado en la sección IV, se introduce el algoritmo empleado de la arquitectura neuronal Fuzzy-ARTMAP seguido por una descripción de la generación de datos utilizados durante la simulación del proceso en la sección V. Posteriormente se muestran los resultados obtenidos experimentalmente y durante la validación del método en las secciones VI y VII respectivamente. Finalmente, las conclusiones y trabajo futuro se mencionan en la sección VIII.

## II. TRABAJO RELACIONADO

Diversas investigaciones sugieren el uso de redes neuronales como una alternativa de control estadístico de procesos considerando las desventajas del uso de técnicas de control tradicionales (Zobel y Cook, 2004; Guh, 2002; Ho y Chang, 1999; Guh y Tannock, 1999; Wani y Pham, 1999; Zorriassantine y Tannock, 1998; Cheng, 1997; Hwang, y Chong, 1995). El uso de las redes neuronales presenta ventajas sobre las técnicas de control estadístico basadas en gráficos de control (Guh, 2005; Zobel y Cook, 2004; Pacella et al., 2004; Swift, 1987). Las ventajas principales son: i. Reconocimiento de patrones en tiempo real (Ruey y Guh, 2005). ii. No se requiere del supuesto de normalidad en los datos o de la independencia de los mismos (Pacella et al., 2004). iii. Se pueden procesar grandes cantidades de datos complejos en poco tiempo (Massimo y Quirico, 2005). iv. Los GC no están diseñados para la detección de patrones, a diferencia de las RNA que lo hacen de forma sistemática.

Guh propone el uso de la red neuronal denominada Back-Propagation (BPN) en combinación con un árbol de decisión que en conjunto incluye un proceso para el reconocimiento de patrones estadísticos de los datos en tiempo real (Guh, 2005). Hindi, usó la red neuronal Fuzzy ARTMAP para determinar el tipo de cambio presentado en los parámetros del proceso, la media ( $\mu$ ) y la desviación estándar ( $\sigma$ ), por separado y de forma simultánea. Compara estos resultados con los obtenidos por la aplicación de los gráficos de control para la media y rangos, o bien,  $\bar{x} - R$ . Usó los valores 0 y 3 para  $\mu$  y 1 y 3 para  $\sigma$ , considerando la combinación  $\mu = 0$  y  $\sigma = 1$  para representar un estado de control estadístico del proceso. Hizo este estudio a valores fijos de los parámetros de la red neuronal (Hindi, 2004).

Esta investigación ha tomado como base los trabajos mencionados y se han identificado áreas de oportunidad en términos de la RNA en aspectos de selección de sus parámetros en el caso específico de FuzzyARTMAP con el objetivo de maximizar su eficiencia.

## III. CARACTERÍSTICAS DE LOS PATRONES

Los patrones de datos de una variable aleatoria  $X$  pueden ser modelados mediante la simulación de Monte Carlo, usando la ecuación:

$$X_t = \mu + n_t + d_t \quad (1)$$

donde  $X_t$  es el valor de dicha variable en el tiempo "t";  $\mu$ , es el efecto de la media global;  $n_t$ , es el efecto de la variación natural en el tiempo "t" y  $d_t$  es el efecto de la variación especial en el tiempo "t" (Ruey y Guh, 2005). Con esta ecuación se explican los tipos de patrones siguientes.

**Natural.** Se presenta cuando el conjunto de datos tiene un comportamiento grafico aleatorio y  $n_t > 0$  y  $d_t \rightarrow 0$ .

**Cambio en el nivel de la media (superior e inferior).** Se explica como un cambio repentino y abrupto del valor de  $\mu$  hacia otro valor, superior o inferior. Se hace referencia a dos medias poblaciones,  $\mu_1$  y  $\mu_2$  separadas en el punto "t" donde ocurre ese cambio de magnitud "d".

**Tendencia creciente o decreciente.** En este patrón una serie de datos de  $X$  presenta la característica de que para toda t,  $X_t < X_{t+1}$  (tendencia creciente) y  $X_t > X_{t+1}$  (tendencia decreciente). La magnitud de la diferencia aritmética  $X_{t+1} - X_t$  está relacionada con la pendiente de la recta de ajuste.

Estos patrones pueden denotar estados estables e inestables del control estadístico del proceso de manufactura. Para el caso del patrón natural, mientras  $\mu$  y la variación de  $X$ , ( $n_t$ ), se mantengan cercanas o iguales al valor deseado, el estado será de control estadístico. Si alguno de estos dos valores o ambos cambian, entonces el proceso de manufactura adoptará inestabilidad (Evans y Lindsay 1993).

Los patrones especiales ocurrirán cuando la diferencia entre las variaciones especial y natural sea significativa ( $a = VE - VN$ , o bien,  $a = d_t - n_t$ , para  $a > 0$ ). A partir de este punto "a", la distribución de probabilidad de  $X$  pasará de normal a no normal. La figura 1 muestra la asociación entre dos tipos de patrones (natural y cambio en el nivel de la media) y la distribución de probabilidad de los datos. La figura 1a, corresponde a la distribución de probabilidad asociada al patrón natural, que se muestra en la figura 1b. Este patrón genera distribuciones normales. La figura 1c es la distribución normal de probabilidad de un conjunto de datos que sigue un patrón especial (figura 1d), pero cuya diferencia  $VE - VN$  es poco significativa como para hacer asimétrica a la distribución. Cuando  $VE - VN$  es

significativa, el patrón especial es claramente distinguible (figura 1f) y la forma de la distribución de probabilidad ya no es normal (figura 1e). Con esto, se pretende mostrar que existe una relación entre la forma de la distribución de probabilidad de un conjunto de datos y el tipo de patrón que siguen (especial o no especial), lo cual es importante para comprender como la red neuronal puede confundirse en la clasificación de patrones de dos clases, pero que compartan una misma forma de distribución (la normal).

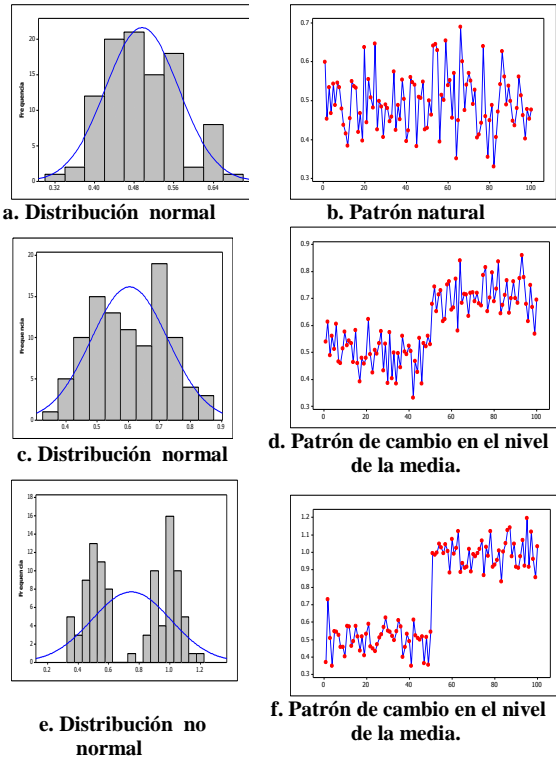


Figura. 1. Relación entre distribuciones de probabilidad y patrones de variación.

#### IV. FUZZY ARTMAP

La arquitectura Fuzzy ARTMAP (Carpenter et al., 1992) es una red neuronal artificial perteneciente a la familia de ART (Adaptive Resonance Theory). Esta teoría fue desarrollada por Grossberg y Carpenter en la Universidad de Boston. Fuzzy ARTMAP puede efectuar aprendizaje supervisado. Esta red neuronal crea varias neuronas de acuerdo al número de patrones presentados en su entrenamiento y a las diferencias entre ellos. Está basada en las siguientes características. Ver figura 2. Esta red tiene dos módulos Fuzzy ART, uno para manejar las entradas y el segundo para las salidas ( $ART_a$  y  $ART_b$ ). También tiene un campo de correspondencia  $F^{ab}$  que liga las clases de entrada con las de salida.

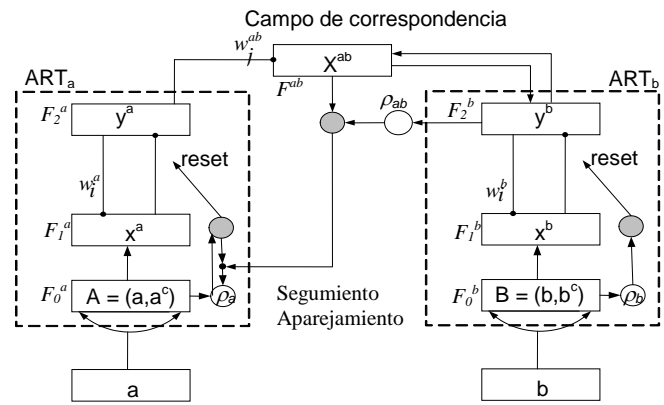
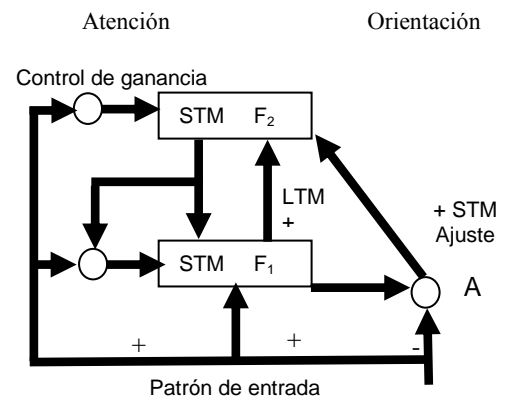


Figura. 2 Arquitectura FuzzyARTMAP

La forma de operación de un módulo básico ( $ART_a$  ó  $ART_b$ ) opera como un módulo básico ART como se ilustra en la figura 3. Dicho modulo consta de 2 subsistemas, atención y orientación. El primer subsistema consta de dos capas de nodos hacia arriba,  $F_1$  y  $F_2$  que representan la memoria de corto plazo (STM), que a su vez están unidas por los pesos ajustables de largo plazo (LTM).

Así, la información de salida del elemento de procesamiento reverbera hacia atrás y hacia delante entre las dos capas. Si una resonancia estable toma lugar entonces puede ocurrir aprendizaje o adaptación. El subsistema de orientación reinicia el subsistema de atención cuando ocurre un evento no común. Si el patrón de entrada no es reconocido inmediatamente entonces la red entrara a un estado de resonancia, después de lo cual un nuevo patrón es almacenado por primera vez. De este modo la red responde rápidamente a datos aprendidos



previamente.

Figura. 3. Arquitectura básica ART

El parámetro de vigilancia de la red ( $\rho$ ) mide la diferencia permitida entre los datos de entrada y los patrones almacenados. Por tanto este parámetro es el determinante para afectar a la selectividad o granularidad de la predicción de la red. Este parámetro tiene 3 factores:

vigilancia a la entrada (vigilancia base) ( $\rho_a$ ), vigilancia de salida ( $\rho_b$ ) y vigilancia de mapeo ( $\rho_{ab}$ ).

### V. GENERACIÓN DE DATOS.

Usando simulación de Monte Carlo, se obtuvieron los vectores de datos de X con los patrones natural, cambio superior en la media, cambio inferior en la media, tendencia creciente y tendencia decreciente.

Para el patrón natural se consideraron los valores  $\mu = 0$  y  $3$  y  $\sigma = 1$  y  $3$  en cuatro combinaciones ( $\mu, \sigma$ ), que son: A (0,1), B(0,3), C (3,1) y D (3,3). A representa el caso de estabilidad. Los patrones especiales con patrón natural son los casos B, C y D. Los patrones especiales con patrón no natural y distribución no simétrica se obtuvieron variando el término “d” en la ecuación (1). El patrón de cambio en el nivel de la media se generó con  $d = 3\sigma$  y  $4\sigma$  (cambio superior) y  $d = -3\sigma$  y  $-4\sigma$  (cambio inferior). El patrón de tendencia, se obtuvo a partir de  $d = 0.1\sigma$  y  $0.15\sigma$  (creciente) y  $d = -0.1\sigma$  y  $-0.15\sigma$  (decreciente).

Los datos generados por este proceso, fueron estandarizados y codificados. La estandarización consiste en transformarlos a una serie de de datos con media 0 y varianza 1, mediante la ecuación  $z = (x-\mu)/\sigma$ . La codificación de los datos estandarizados se hizo convirtiendo éstos a su equivalente en el intervalo [0,1], ya que esto es requisito de operación de la red neuronal.

### VI. EXPERIMENTACIÓN.

Se desarrollaron dos experimentos. El primero para el reconocimiento de patrones naturales y el segundo para patrones no naturales. El diseño de los experimentos, así como los análisis, fueron hechos con *Minitab® Statistical Software*.

#### a. Experimentación con patrones naturales.

Se empleo el proceso generador de variables aleatorias con distribución normal *normrnd* ( $\mu, \sigma$ ) de *MATLAB®* para obtener los vectores de datos de la variable aleatoria X, tanto para el *entrenamiento* de la red neuronal como para la *prueba* en la fase experimental. Se generaron 100 vectores por caso (A, B, C y D) de 20 elementos cada uno tanto para entrenamiento como para prueba. La tabla I muestra el resumen del diseño de este experimento. Al correr este experimento se generó el análisis de varianza (ANOVA) para detectar si hay factores de prueba que son significativos en la eficiencia de predicción de la red neuronal. El ANOVA se muestra en la tabla II. Dado que con la información obtenida por la ANOVA solo se puede identificar que existen factores significativos (efectos principales y curvatura, al ser  $p < 0.05$ ), mas no cuales son éstos, fue necesario construir la gráfica de los efectos principales para observar las pendientes de cada uno de los factores. Una

pendiente alta esta relacionada con la significancia del factor. Ver figura 4.

De la observación de la figura 4, se dedujo que solo el parámetro de *vigilancia de salida* es significativo, ya que la pendiente de su recta es notablemente mayor a cero, lo que no ocurre con el otro factor. También, de esta figura se observa que el mejor nivel de eficiencia del mencionado factor es a partir de 0.7. También se observa que el comportamiento de este parámetro de la red no es lineal, sino presenta un nivel de curvatura como se indica en la tabla II. El subíndice 1 y 2 en todos los casos se refiere al valor utilizado de los factores para la RNA durante la fase de entrenamiento y prueba, respectivamente.

TABLA I  
Diseño experimental para patrones naturales

CONCEPTO	VALOR
Tipo de experimento	$2^2$ con 1 punto al centro
Número de factores	2
Número de réplicas	2
Número de corridas	9
Variables de respuesta	Eficiencia de clasificación <sup>2</sup>
Nivel de significancia	0.05
<b>FACTORES FIJOS</b>	<b>NIVELES</b>
Vigilancia base 1 ( $\rho_{a1}$ )	0.2
Razón de aprendizaje 1 ( $\beta_1$ )	1.0
Vigilancia base 2 ( $\rho_{a2}$ )	0.2
<b>FACTOR DE VARIACION</b>	<b>NIVELES</b>
Vigilancia de salida 1,2 ( $\rho_{b1,2}$ )	0.5      0.9
Razón de aprendizaje 2 ( $\beta_2$ )	0.5      1.0

TABLA II  
Análisis de varianza

FUENTE DE VARIACION	SUMA DE CUADRADOS	G.L.	C.M.	P
Efectos principales	2382.92	2	1191.46	0.001
Interacción	0.00	1	0.00	0.997
Curvatura	249.13	1	249.13	0.017
Error	65.19	4	16.30	
Total	2697.24	8		

G.L.: Grados de Libertad, C.M.: Cuadrados Medios

<sup>2</sup> Entendida como el número de vectores clasificados correctamente dividido por el número de vectores probados y se expresa en porcentaje.




Figura 4. Efectos principales.

b. Experimentación con patrones no naturales.

Se probó una serie de vectores pertenecientes al patrón de cambio en el nivel de la media para observar el comportamiento de la distribución de probabilidad. Se concluyó que la normalidad<sup>3</sup> se conserva si el efecto de la variación especial es no mayor a  $3\sigma$ . La experimentación indicó que la red neuronal no clasifica correctamente este patrón cuando la distribución es normal, confundiendo entonces con el patrón natural. Para corregir este comportamiento, se corrió un experimento factorial fraccionado, a dos niveles con 7 factores (los parámetros de la red neuronal) para determinar la importancia de éstos en la eficiencia de la red neuronal. Los datos de la planeación se muestran en la tabla III. Se generaron 50 vectores de tamaño 20 por patrón, tanto para entrenamiento como para prueba.

TABLA III

Diseño experimental para patrones no naturales.

CONCEPTO		VALOR	
Tipo de experimento		2 <sup>k</sup> fraccionado	
Número de factores		7 a dos niveles	
Resolución		III	
Número de réplicas		2	
Número de corridas		18	
Puntos centrales		2	
Diseño generador de alias		D = AB, E = AC, F = BC, G = ABC	
FACTORES		NIVELES	
DESCRIPCIÓN		BAJO	ALTO
A	Vigilancia base <sub>1</sub> ( $\rho_{a1}$ )	0.2	0.8
B	Vigilancia mapeo <sub>1</sub> ( $\rho_{ab}$ )	0.2	0.8
C	Razón de aprendizaje <sub>1</sub> ( $\beta_1$ )	0.2	1
D	Vigilancia de salida <sub>1,2</sub> ( $\rho_{b1,2}$ )	0.2	0.8
E	Vigilancia mapeo <sub>2</sub> ( $\rho_{ab}$ )	0.2	0.9
F	Razón de aprendizaje <sub>2</sub> ( $\beta_2$ )	0.2	1
G	Vigilancia base <sub>2</sub> ( $\rho_{a2}$ )	0.2	0.8

La ANOVA (tabla IV) indica  $p < 0.05$  para efectos principales en los siete factores y para efecto de curvatura. Los mejores niveles son el bajo para Vigilancia base<sub>1</sub>, Vigilancia de mapeo<sub>1</sub>, Razón de aprendizaje<sub>1</sub> y Vigilancia base<sub>2</sub> y alto para Vigilancia de salida<sub>1,2</sub>, Vigilancia de mapeo<sub>2</sub> y Razón de aprendizaje<sub>2</sub>.

TABLA IV  
Análisis de varianza

FUENTE DE VARIACION	SUMA DE CUADRADOS	G.L	C.M.	P
Efectos principales	7445.56	7	1063	0.000
Curvatura	31.64	1	31.6	0.001
Error	11.90	9	1.32	
Total	7489.10	17		

G.L.: Grados de Libertad, C.M.: Cuadrados Medios

VII. VALIDACIÓN.

Para verificar la validez experimental, se hizo una prueba confirmatoria con 12,500 vectores de tamaño 20 (2,500 por cada patrón probado). El tipo de patrón utilizado y el resultado de la eficiencia de la red se muestran en la tabla V.

TABLA V  
Prueba confirmatoria

PATRÓN	% DE EFICIENCIA
Natural	98.3%
Cambio superior del nivel de la media	96%
Cambio inferior del nivel de la media	80%
Tendencia creciente	86%
Tendencia decreciente	96%

Por otra parte, la validación con datos de producción, no simulados, se hizo con 41 vectores de tamaño de 20 cada uno, cuyos datos numéricos pertenecen a una variable aleatoria con  $\mu = 387.63$  y  $\sigma = 71.71$  que representa el peso en gramos de un producto alimenticio. En el primer momento de prueba, la red neuronal clasificó correctamente a 32 vectores; en un segundo momento, cuando la red neuronal aprendió las características específicas de un patrón especial de tendencia decreciente, la eficiencia se elevó a 39 vectores identificados correctamente.

De estos 41 casos, 11 pertenecieron al patrón natural en estado estable, 11 al patrón de tendencia decreciente en estado inestable del proceso y 19 al patrón de tendencia

<sup>3</sup> Prueba hecha con Anderson-Darling



creciente en estado inestable del proceso. La red neuronal erró en la clasificación de 2 vectores, de los 11 con tendencia decreciente, en estado inestable.

Los mismos vectores fueron procesados por el gráfico de control de lecturas individuales y se obtuvieron resultados similares en el 83% de los casos en cuanto a la conclusión de estabilidad/inestabilidad del proceso de producción<sup>4</sup>. El 17% restante se explica al determinar que dicho gráfico de control no es el adecuado para este tipo de datos, existiendo gráficas de control más apropiadas que el de lecturas individuales.

### VIII. CONCLUSIONES Y TRABAJO FUTURO

Con la presente investigación se muestra como se obtienen resultados satisfactorios en la eficiencia de la red neuronal al separar los patrones especiales de variación de los no especiales a través de la forma de su distribución de probabilidad, concluyendo que si un conjunto de datos tiene distribución de probabilidad normal, entonces la red neuronal podrá clasificarlo como patrón natural; no obstante, si el patrón es especial, entonces la clasificación corresponderá a un patrón natural con cambio en alguno de los parámetros  $\mu$  o  $\sigma$ , siempre y cuando la diferencia entre la variación natural y la especial sea significativa. Esta diferencia es significativa si su magnitud es  $\pm 3\sigma$  a partir del valor de  $\mu$  (patrón de cambio en el nivel de la media) y  $\pm 0.15\sigma$  (patrón de tendencia).

Con esta investigación se prueba que la identificación de estados de control del proceso mediante la red neuronal Fuzzy-ARTMAP es factible si se entrena con técnicas experimentales planeadas para la determinación de los valores significativos de sus parámetros de acuerdo a los tipos de patrones a identificar. Al ser posible esto, entonces el trabajo futuro consiste en el diseño de un sistema de control automático de procesos de manufactura que incorpore esta tecnología al sistema de control del proceso en tiempo real.

### IX. AGRADECIMIENTOS.

Los autores agradecen al CONACyT tanto por el apoyo otorgado durante los estudios doctorales de José Antonio Vázquez López dentro del Programa Interinstitucional en Ciencia y Tecnología (PICyT) como el apoyo al proyecto 61373 de Ciencia Básica. También agradecen al M.C. Edgar Hernández López su apoyo en el trabajo realizado.

### REFERENCIAS

- Carpenter, G.A.; Grossberg, S., Markuzon, N.; Reynolds, J.H.; and Rosen, D.B. (1992). Fuzzy ARTMAP: A neural network architecture for incremental learning of analog multidimensional maps." *IEEE Transactions on Neural Networks* 3 (5), pp. 698- 713.
- Chang, S.I., Ho, E.S., (1999). A two-stage neural network approach for process variance change detection and classification. *International Journal of Production Research* 37 (7), 1581–1599.
- Cheng, C.S., (1997). A neural network approach for the analysis of control chart patterns. *International Journal of Production Research* 35 (3), 667–697.
- Evans, James R. and M. Lindsay, (1993). *William. The Management and Control of Quality*, St. Paul, MN USA. West Publishing Company.
- Guh, R. S. and Tannock, J. D. T. (1999). Recognition of control chart concurrent patterns using a neural network approach. *Int. J. Prod. Res.*, 37(8), 1743–1765.
- Guh, R.S. (2002). Robustness of the neural network based control chart pattern recognition system to non-normality. *Int. J. Qual. Reliability Mgmt*, 19(1), 97–112.
- Guh R.S. (2005). Real-time pattern recognition in statistical process control: a hybrid neural network/decision tree-based approach. *IMechE*, Vol. 219 Part B: *J. Engineering Manufacture*.
- Hindi A. Al-Hindi (2004). Control Chart Interpretation Using Fuzzy ARTMAP. *Journal of King Saud University. Engineering Sciences*. Volume 16, No 1.
- Ho, E. S. and Chang, S. I. (1999). An integrated neural network approach for simultaneous monitoring of process mean and variance shifts – a comparative study. *Int. J. Prod. Res.*, 37(8), 1881–1901.
- Hwang, H. B. and Chong, C.W. (1995). Detecting process nonrandomness through a fast and cumulative learning ART-based pattern recognizer. *Int. J. Prod. Res.*, 33(7), 1817–1833.
- Pacella M, Q. Semeraro, A. Anglania (2004). Manufacturing quality control by means of a Fuzzy ART network trained on natural process data, *Engineering Applications of Artificial Intelligence* 17. 83–96.
- Pacella, M and Semeraro, Q. (2005). Understanding ART-based neural algorithms as statistical tools for manufacturing process quality control. *Engineering Applications of Artificial Intelligence*. 18, 645–662
- Swift, J. A. (1987). Development of a Knowledge-Based Expert System for Control Chart Pattern Recognition and Analysis, Doctoral Thesis, Oklahoma State University.
- Wani, M. A. and Pham, D. T. (1999). Efficient control chart pattern recognition through synergistic and distributed artificial neural networks. *Proc. Instn Mech. Engrs, Part B: J. Engineering Manufacture*, 213(B2), 157–169.
- Zobel C.W. and Cook D.F., Q.J. (2004). Nottingham, An augmented neural network classification approach to detecting mean shifts in correlated manufacturing process parameters, *International Journal of Production Research* 42 (4) 741–758.
- Zorriassantine, F., Tannock, J.D.T., (1998). A review of neural networks for statistical process control. *Journal of Intelligent Manufacturing* 9, 209–224.

<sup>4</sup> Como se mencionó, los gráficos de control no están diseñados para clasificar patrones de variación.