Modelo de ensamble de múltiples redes neuronales artificiales para el monitoreo estadístico de patrones en procesos bivariantes



An ensemble model for statistical monitoring of patterns in bivariate processes based on multiple artificial neuronal networks

Aideé Hernández-López[1], José-Antonio Vázquez-López[2], Ismael López-Juárez[3], Roberto Baeza-Serrato[4] y José-Amir González-Calderón[5]

[1] PICyT-CIATEC). Omega no. 201 Col. Industrial Delta - 37545 León, Guanajuato (México).
[2] Tecnológico Nacional de México en Celaya. Dpto. de Ingeniería Industrial. Antonio García Cubas, 600 - 38010 Fovissste, Celaya, Guanajuato (México).
[3] Centro de Investigación y Estudios Avanzados del IPN. Dpto. de Robótica y Manufactura Avanzada. Zona Industrial - 25900 Ramos Arizpe, Coahuila (México).
[4] Universidad de Guanajuato. Departamento de Estudios Multidisciplinarios. Av. Universidad, s/n – 38940 Colonia Yacatitas, Yuriria, Guanajuato (México).
[5] Universidad Autónoma de San Luis Potosí (IF-UASLP). CONACYT Instituto de Física. Alvaro Obregón, 64 - 78000 San Luis Potosí (México).

DOI: http://dx.doi.org/10.6036/9222 | Recibido: 23/04/2019 • Inicio Evaluación: 25/04/2019 • Aceptado: 02/09/2019

ABSTRACT

- Multivariate control graphics detect signals out of control of the process. These signals are special patterns of joint variation, but they do not allow to determine what types of variation patterns take place in the individual variables. The referred problem has been treated through models of pattern recognition (PR) by Artificial Neural Networks (ANN). There are important advances in solving the problem to univariate cases, but not so in multivariate cases. There is no research which affirms that a single ANN can identify a multivariate out-of-control signal and recognize the special variation types of the variables individually. This research presents a model of PR of special variation in bivariate processes, and is based on an organized assembly of different types of ANN which are activated sequentially. With this work, it is possible to obtain a diagnosis of the bivariate process control that simultaneously recognizes the type of variation of the variables involved. This novel model provides the basis of new knowledge about statistical control of bivariate processes by PR through ANN. The model had two stages of training: experimental and industrial. The first one worked with data generated by Montecarlo simulation and the second one with data from a process that performs manufactured operations on metal bars used in the speed system in automobiles.
- **Keywords:** Statistical quality control, Pattern recognition, Artificial neural networks, Perceptron, Backpropagation.

RESUMEN

Los gráficos de control multivariante detectan señales fuera de control del proceso. Estas señales son en si patrones especiales de variación conjunta, pero no permiten determinar que tipos de patrones de variación ocurren en las variables individuales. El problema referido ha sido tratado mediante modelos de reconocimiento de patrones (RP) por Redes Neuronales Artificiales (RNA). Existen avances importantes en la solución del problema en casos univariantes, pero no así en casos multivariantes. No hay alguna investigación que afirme que una sola RNA puede identificar una señal fuera de control multivariante y reconocer los tipos de variación especial de las variables individualmente. Esta investigación presenta un modelo de RP de variación especial en procesos bivariantes, y se sustenta en un ensamble organizado de distintos tipos de RNA que se activan secuencialmente. Con este trabajo se pueden obtener diagnósticos del control del proceso bivariante que reconozca simultáneamente el tipo de variación de las variables involucradas. Este modelo es novedoso y proporciona las bases del nuevo conocimiento sobre control estadístico de procesos bivariantes por RP a través de RNA. El modelo tuvo dos etapas de entrenamiento: la experimental y la industrial. La primera con datos generados por simulación de Montecarlo y la segunda con datos de un proceso de manufactura que realiza operaciones de maquinado en barras metálicas usadas en el sistema de transmisión de velocidad en los automóviles.

Palabras clave: Control estadístico de la calidad, Reconocimiento de patrones, Redes neuronales artificiales, Perceptron, Backpropagation.

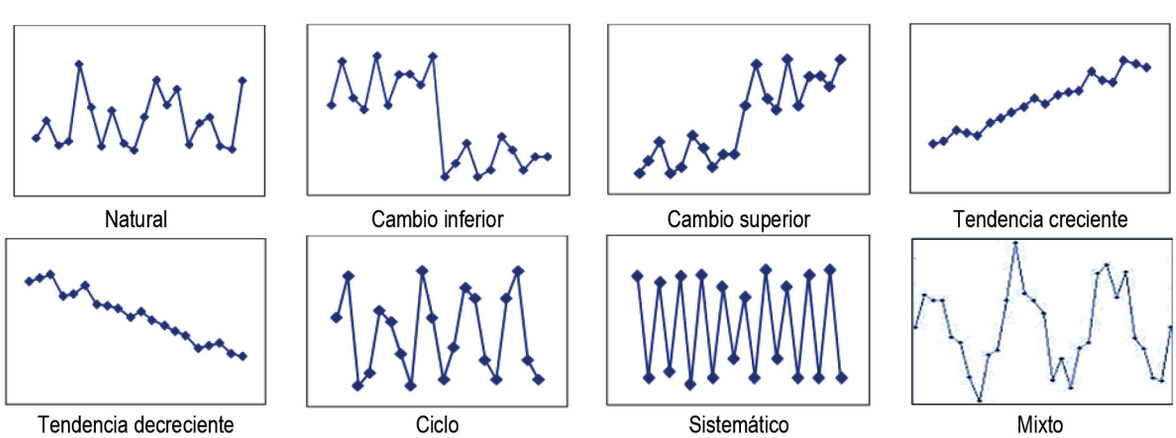


Fig. 1: Patrones básicos en GC

1. INTRODUCCIÓN

Los gráficos de control (GC) usados para mejorar la calidad de la producción se presentan en dos tipos de casos: univariantes y multivariantes. Estos gráficos son aplicados con el objetivo de identificar los dos estados de control estadístico de la calidad de los procesos, que son "estado estable" y "estado no estable"[1]. El primer estado se relaciona con la variación natural (VN) de un conjunto de datos y el segundo con la variación especial (VE). Si la variación total (VT) de los datos se puede expresar como VN + VE y en la VT se reconoce que existen patrones identificables, entonces habrá dos grandes grupos de patrones, los naturales (si VE no es significativa) y los especiales (si VE es significativa) [2-3]. Los GC tienen la tarea de mostrar visualmente el patrón de los datos (ver Fig. 1) para determinar los estados de control mencionados [4-7] siendo éstos, para estado estable, el patrón Natural (N) y para el estado no estable: Cambio inferior (CI), Cambio superior (CS), Tendencia creciente (TC), Tendencia decreciente (TD), Ciclo (C) Sistemático (S) y Mixto (M) [4-6, 8]. El tema principal de este artículo es el de reconocimiento de patrones (RP) tanto natural como especiales.

1.1 TRABAJO RELACIONADO Y CONTRIBUCIÓN ORIGINAL

Los productos fabricados suelen tener más de una característica de calidad importante y para las cuales se aplica monitoreo estadístico a través de GC. Si interesa el RP en situaciones de dos o más variables, entonces se define un proceso de monitoreo multivariante y de forma especial, si dicho interés recae en sólo dos variables, se tiene el caso bivariante. Los GC tradicionales bivariantes no son efectivos para el RP y menos cuando las características de calidad vistas como variables aleatorias están interrelacionadas entre sí. Con ello se identifica y hace necesario el RP por medios avanzados. El estudio del RP bivariante llama la atención de los investigadores ya que los avances en este tema no son suficientes, por lo que es un área de investigación abierta [6, 7-11].

Un enfoque tradicional de monitoreo bivariado (multivariante) no permite el RP sobre los patrones de la Fig. (1) en las dos variables. Entre los GC convencionales se tienen al T^2 de Hotelling (o el χ^2 cuando se conoce la matriz de covarianza del proceso) [12], el de sumas acumuladas (CUSUM) [13] y el multivariante de medias móviles exponencialmente ponderadas (MEWMA) [14]. Estos GC pueden capturar efectivamente las señales de pérdida de control en los procesos, pero ninguno puede proveer información acerca de las variables causantes de esto, como tampoco realizan el RP en los datos y variables. Esa información no identificada es de gran importancia para la solución de los problemas que intentan resolver los GC en los procesos [15]. La tendencia actual para el RP en casos univariantes y bivariantes consiste en el uso de redes neuronales artificiales (RNA) y diversos autores han publicado al respecto, como puede verse en [4-5, 9-11, 16-26]. Ninguna de estas investigaciones atiende el problema de RP para todos los patrones de la Fig. (1) y tampoco muestran si una única RNA es capaz de resolver el problema, por lo que se observa que el problema de RP bivariante es un caso complejo que demanda más allá del uso de una RNA conocida.

Otros enfoques basados también en RNA han sido investigados intensamente y algunos están basados en técnicas de aprendizaje automático [27]. Se observa que presentan en el uso práctico algunas limitaciones, pues su objetivo es minimizar el riesgo empírico de reconocer patrones erróneamente por lo que son necesarias grandes cantidades de datos para el entrenamiento. También se advierte sobre el riesgo de sobreajuste en el entrenamiento de la RNA y una pobre generalización [27]. En [28] se presenta un método de aprendizaje profundo para identificar patrones en procesos multivariantes de manufactura; este método muestra la capacidad de reconocer varios patrones en procesos multivariantes. El aprendizaje profundo es actualmente una de las herramientas de la inteligencia artificial utilizada en el control estadístico multivariante de procesos.

Otro enfoque de atención al problema planteado se puede ver en [1] donde los autores muestran un método basado en la reducción de dos dimensiones, una por cada variable del caso bivariante, a una dimensión, para hacer menos complejo el problema. Buscan demostrar que las dos variables pueden trasferir sus "propiedades de forma" de los patrones a una posición única dentro de una dimensión, esto es, que a cada combinación de dos patrones corresponde un punto en una escala. Este enfoque resulta comparable con el uso de componentes principales, en cierto modo, pero la base de razonamiento es diferente. En la presente investigación no se recurre a la reducción dimensional para atender el problema. Por otra parte, en [6] los autores realizan un análisis comparativo de técnicas clásicas de monitoreo multivariente, que son T^2 de Hotelling y MEWMA con dos tipos de RNA (perceptrón y backpropagation). Aquí conluyen que éstas RNA son eficientes para el RP por lo que ambas fueron la base para la construcción del modelo desarrollado en esta investigación.

Con la revisión de la literatura se conluye que el problema en atención de los GC bivariantes radica en cómo identificar a la variable o grupo de variables causantes de un patrón multivariante asociable a una señal de "estado no estable" en el proceso. Esto se confirma en [8] quien comenta que para un proceso multivariante, esto no ha sido definido aún. En consecuencia se ha desarrollado la propuesta mostrada en este artículo que tiene como propósito detectar patrones especiales en el caso bivariante que den orígen a un estado no estable del proceso y al mismo tiempo determinar que tipo de patrón especial se está presentando en ambas variables, lo que al mejor entedimiento de los autores, ello constituye el trabajo original de la investigación que se suma a las investigaciones más actuales sobre el tema.

1.2. APLICACIÓN INDUSTRIAL

Se consideró como caso de aplicación industrial al proceso de maquinado sobre barras metálicas empleadas en el sistema de la transmisión de los automóviles. Los maquinados se muestran en la Fig. (2). Para que cada barra cumpla con las especificaciones de calidad deben revisarse las siguientes características de calidad: concentricidad, longitud y profundidad de barrenado (ver Fig. 2). Estas características de calidad son identificadas mediante instrumentos de medición y registradas en una hoja de verificación. Se realizó un estudio de correlación de variables y se determinó que de las tres sólo concentricidad y profundidad de barrenado lo es-

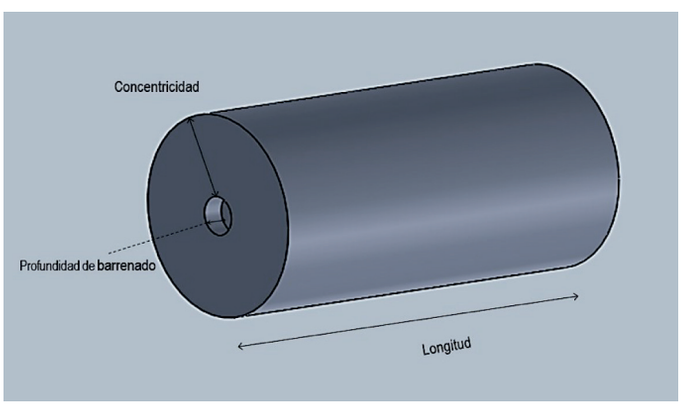


Fig. 2: Características de calidad de una barra metálica

tán de manera significativa por lo que se eligieron estas variables para el caso de aplicación industrial.

En estas dos variables se observó la presencia de solo 5 patrones de los mostrados en la Fig. (1). Los patrones detectados fueron TC, TD, CS, CI y N en las dos variables. Por tanto, el trabajo de investigación se enfocó en atender a estos patrones que fueron diagnosticados "fuera de línea" mediante técnicas estadísticas básicas. De este modo se genera la Fig. (3), que muestra 15 casos de combinaciones de los 5 patrones en las 2 variables.

x_1 \ x_2	TC	TD	CS	CI	N
TC	Caso 1	Caso 2	Caso 3	Caso 4	Caso 5
TD		Caso 6	Caso 7	Caso 8	Caso 9
CS			Caso 10	Caso 11	Caso 12
CI				Caso 13	Caso 14
N					Caso 15

Fig. 3: Casos de patrones bivariantes de la aplicación industrial

2. MODELO DE ENSAMBLE DE MÚLTIPLES RNA (MERNA)

2.1. BASES DE DATOS PARA EL ENTRENAMIENTO DE LAS RNA

En el Modelo propuesto (Fig. 4) que contiene un ensamble de RNA se aplicó para el entrenamiento de estas redes los conceptos de base de datos inicial (BDI) y base de datos mejorada (BDM) expuestos por [5], con lo cual se logra incrementar rápidamente la eficiencia de entrenamiento. La BDI esta compuesta por 300 vectores de tamaño 12 cada uno y fueron generados por simulación de Montecarlo de acuerdo al proceso mostrado en [4-5], siendo la ecuación (1) la función generadora de datos con los patrones establecidos.

$$x_t = \mu + n_t + d_t \tag{1}$$

Donde:

μ = media global del proceso,
n_t = componente de VN como variable aleatoria con distribución normal estándar
d_t = componente de VE que es el término de alteración a estado estable del proceso

Los valores de este último componente para los patrones empleados son: N (d_t = 0.0), TC (d_t = 0.2*t), TD (d_t = -0.2*t), CSM (d_t = 2.0 en t = 6) y CIM (d_t = -2.0 en t = 6) usados todos para μ = 0 y σ = 1 sobre una base de distribución normal.

Se asume que los entrenamientos de las distintas RNA del modelo aplicados sobre la BDI genera buenos valores de entrenamiento, los cuales constituyen la mejor base de partida para los entrenamientos de las mismas RNA al agregar a la BDI los *nuevos vectores* de datos tomados del caso industrial para obtener con ello la BDM. Así se aplica un enfoque de entrenamiento de la BDM en dos etapas, la que corresponde a datos simulando patrones bien definidos y la segunda aplicada a los vectores de datos reales combinados con los patrones simulados. Para obtener la BDM se obtuvieron 250 vectores de datos reales con distintos patrones, mismos que fueron agregados a la BDI para obtener finalmente que la BDM = BDI + 250 vectores de datos reales, cuenta con 550 vectores.

2.2. DESCRIPCIÓN DEL MERNA

MERNA (Fig. 4) consta de tres bloques de trabajo: Tratamiento de los datos (o pre procesamiento), Ensamble neuronal clasificador y Patrones bivariantes identificados. En el bloque 1 los vectores bivariantes son tratados estadísticamente para incrementar la eficiencia de la clasificación del modelo global. En el bloque 2 los vectores de salida del bloque 1 serán procesados por una o más RNA para obtener o bien la salida al bloque 3 o para clusterizar en familias a los patrones. El bloque 3 es donde se clasifica el tipo de patrón y en consecuencia el estado del proceso. La parte central del MERNA consta de seis RNA (llamadas clasificadores) interconectadas que actúan como una red general con entradas y salidas (ver parte central de la Fig. 4).

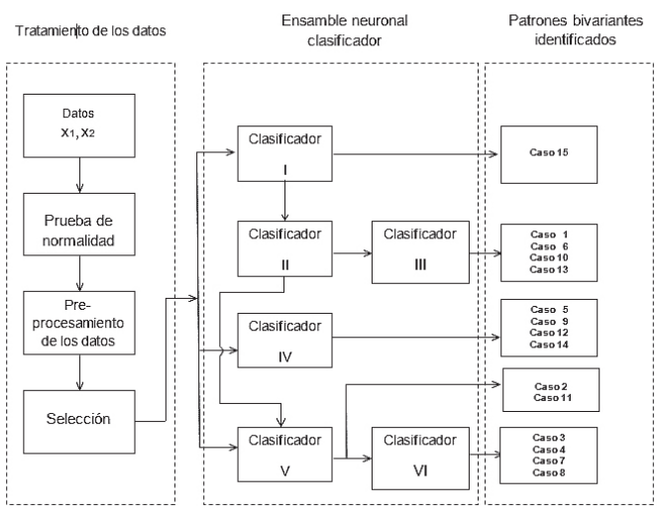


Fig. 4: MERNA para identificación de patrones bivariantes

Bloque 1. Tratamiento de datos

Sea X una variable aleatoria bivariante compuesta por X_1 y X_2 de tal modo que $\mathbf{X} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$, donde $x_1 = [x_{11}, x_{21}, \ldots, x_{n1}]^T$ y $x_2 = [x_{21}, x_{22}, \ldots, x_{n2}]^T$ son las variables aleatorias univariantes que representan a dos características de calidad de un producto manufacturado.

Prueba de normalidad. Se realiza la prueba de normalidad de Kolmorov-Smirnov a los vectores de datos **X**.

Preprocesamiento de los datos. Para **X**, sea $\bar{\mathbf{X}}$ el vector de medias calculado como en la Ecuación 2 y **S** el vector de desviaciones estándar calculado conforme a la Ecuación 3.

$$\bar{\mathbf{X}} = \begin{bmatrix} \bar{x}_1 \\ \bar{x}_2 \end{bmatrix} = \begin{bmatrix} \frac{1}{n}\sum_{i=1}^{n} x_{1i} \\ \frac{1}{n}\sum_{i=1}^{n} x_{2i} \end{bmatrix} \tag{2}$$

$$\mathbf{S} = \begin{bmatrix} S_1 \\ S_2 \end{bmatrix} = \begin{bmatrix} \frac{1}{n-1}\sqrt{\sum_{i=1}^{n}(x_{1i} - \bar{x}_1)^2} \\ \frac{1}{n-1}\sqrt{\sum_{i=1}^{n}(x_{2i} - \bar{x}_2)^2} \end{bmatrix} \tag{3}$$

Entonces, sea $\mathbf{A} = \begin{bmatrix} a_{11} \\ a_{12} \end{bmatrix}$ el vector de las señales de entrada consideradas para el MERNA expuesto en la Fig. (4). El vector **A**

Característica	Clasificador*					
	I	II	III	IV	V	VI
Tipo de RNA	Per	BP	Per	Per	Per	BP
Señal de entrada	A	A	A	A	A	A
Cantidad de capas	1	3	2	2	2	3
Cantidad de neuronas por capa	[1]	[2,10,1]	[2,2]	[2,2]	[2,2]	[2,10,1]
Función de transferencia	Límite duro	Purelin Tansig	Límite duro	Límite duro	Límite duro	Purelin Tansig
Tipo de salida	[(0,1)]	[(0,1)]	[(0,0), (0,1), (1,0), (1,1)]	[(0,0), (0,1), (1,0), (1,1)]	[(0,0), (0,1), (1,0), (1,1)]	[(0,0), (0,1), (1,0), (1,1)]
Medida de desempeño para convergencia	EMA	ECM	EMA	EMA	EMA	ECM
Función de entrenamiento	Trainc MATLAB	Traingd MATLAB	Trainc MATLAB	Trainc MATLAB	Trainc MATLAB	Traingd MATLAB

**Per: Perceptron; BP: Backpropagation; EMA: Error medio absoluto; ECM: Error cuadrado medio.*
Tabla 1: Características de los clasificadores por RNA

se obtiene aplicando los resultados de las Ecuaciones 2 y 3 en el arreglo mostrado en las Ecuaciones 4 y 5.

$$\mathbf{A} = f(\mathbf{N}) \tag{4}$$

$$\mathbf{N} = \begin{bmatrix} n_1 \\ n_2 \end{bmatrix} = \begin{bmatrix} \bar{\mathbf{X}}\,\mathbf{X} + b_1 \\ \mathbf{S}\,\mathbf{X} + b_2 \end{bmatrix} \tag{5}$$

Selección. Aquí se identifican los vectores **X** que presentan alguna de las combinaciones de comportamiento estadístico: normal-normal, normal-no normal o no normal-no normal. Esto permite la identificación de la ruta de entrada que seguirán los datos al bloque segundo.

a. Si **X** *es normal-normal entonces* **X** *ingresa a clasificador I.*
b. Si **X** *es normal-no normal, entonces* **X** *ingresa a clasificador IV y*
c. Si **X** *es no normal-no normal, entonces* **X** *ingresa a clasificador V.*

Bloque 2. Ensamble de RNA en MERNA

La Tabla 1 contiene la información de las topologías y otras características de las seis redes que componen al ensamble de RNA. La determinación de la cantidad de capas y neuronas por cada RNA fue hecha por procesos de ensayo y mejora, teniendo los mejores resultados conforme se muestra en la tabla.

Los tipos de salida por clasificador son combinaciones binarias que corresponden al código "testigo" de entrenamiento, siendo de la siguiente manera:

Clasificador I: (1) para el caso 15 de la Fig. (5) y (0) para cualquier otro caso.
Clasificador II: (1) para el clúster de los casos 1, 6, 10 y 13 de la Fig. (5) y (0) para cualquier otro caso.
Clasificador III: (0,0) para el caso 1; (0,1) para el caso 6; (1,0) para el caso 10 y (1,1) para el caso 13 de la Fig. (5).
Clasificador IV: (0,0) para el caso 5; (0,1) para el caso 9; (1,0) para el caso 12 y (1,1) para el caso 14 de la Fig. (5).
Clasificador V: (0,0) para el clúster de los casos 3, 4, 7 y 8; (0,1) para el caso 2 y (1,0) para el caso 11 de la Fig. (5). (1,1) cualquier otro caso, pero se determina como salida falsa.
Clasificador VI: (0,0) para el caso 3; (0,1) para el caso 4; (1,0) para el caso 7 y (1,1) para el caso 8 de la Fig. (5).

La Tabla 2 muestra los casos de combinación de patrones que cada clasificador puede reconocer de los mostrados en la Fig. (3), así como los objetivos de diseño que cada RNA como clasificador cumple dentro del MERNA. Estos objetivos son de dos tipos, clúster o clasificador final. Los clasificadores II y V clusterizan para obtener una parte del total de los casos de RP y que posteriormente en otro clasificador se identifica el caso puntual dentro de estos clústeres. La lectura de esta tabla se completa con la observación de la Fig. (5).

En la Fig. (5), se ilustran por colores los casos agrupados por los clasificadores II (en verde) y V (en azul), verde para el clúster 1,6,10 y 13 y azul para el clúster 3, 4, 7 y 8.

Bloque 3. Patrones bivariantes clasificados

Finalmente, en el último bloque se identifican los patrones bivariantes clasificados por el MERNA, para diagnosticar la estabi-

Clasificador	Objetivo del clasificador	Función en el modelo
I	Clasificador final	Identificar la combinación natural-natural (caso 15).
II	Clúster	Clúster para los casos 1, 6, 10 y 13 que corresponden a la diagonal de la Fig. (3).
III	Clasificador final	Identificar el caso específico del clúster obtenido por el clasificador II.
IV	Clasificador final	Identificar los casos 5, 9, 12 y 14
V	Clúster y clasificador final	Clúster para los casos 3, 4,7 y 8. Identificar los casos 2 y 11.
VI	Clasificador final	Identificar el caso específico del clúster del clasificador V.

Tabla 2: Objetivo de los clasificadores en el MERNA

X	TC	TD	CS	CI	N
TC	Caso 1 II	Caso 2	Caso 3 V	Caso 4 V	Caso 5
TD		Caso 6 II	Caso 7 V	Caso 8 V	Caso 9
CS			Caso 10 II	Caso 11	Caso 12
CI				Caso 13 II	Caso 14
N					Caso 15

Fig. 5: Clusterización con el MERNA

lidad o inestabilidad del proceso y al mismo tiempo los patrones presentados en la variable bivariante estudiada.

3. RESULTADOS

3.1. VALIDACIÓN DEL MERNA (CASO DE ESTUDIO INDUSTRIAL)

Los datos reales considerados en esta investigación corresponden a las características de calidad concentricidad y profundidad de barrenado. Se seleccionaron estas porque en un análisis estadístico se determinó la existencia de correlación significativa entre ambas variables de las tres estudiadas. Con los datos industriales se construyó una BD de vectores bivariantes que fue estudiada por distintos métodos estadísticos y gráficos de control para determinar la combinación de patrones presentes en cada vector bivariante y tener así los vectores testigo para los entrenamientos y prueba de los clasificadores. La eficiencia del MERNA fue calculada por el porcentaje de aciertos en el RP sobre la cantidad de vectores presentes en la BDI y BDM. Un acierto es la identificación correcta de la combinación de patrones del MERNA respecto al resultado esperado tanto en la BDI como en la BDM y posteriormente, la coincidencia con la clasificación hecha por los expertos (columna 8, Tabla 3).

El proceso de validación del MERNA fue el siguiente:

a) Generación de la BDI conforme a lo indicado en la sección 2.1 para obtener los vectores $\mathbf{Y} = [\mathbf{X}_1, \mathbf{X}_2]$.
b) Aplicación de las Ecuaciones 2 y 3 en Y para la obtención de los vectores de la media y desviación estándar de cada **X** en **Y**.
c) Obtención de A a partir de la Ecuación 4.
d) Entrenamiento del MERNA con la BDI y cálculo de la eficiencia en el RP de cada clasificador ver columna 1 de la Tabla 3.
e) Colecta de datos industriales de las dos variables aleatorias bajo estudio, $\mathbf{W} = [\mathbf{Z}_1, \mathbf{Z}_2]$.
f) Obtener la BDM agregando **W** a **Y** y probar con los valores de entrenamiento de las RNA obtenidos con las BDI. Dado que los tipos de patrones en **W** son conocidos se puede calcular la eficiencia del MERNA sobre la BDM y esto se muestra en la columna 2 de la Tabla 3.
g) Reentrenamiento de las RNA del MERNA hasta obtener convergencia. La eficiencia del RP se observa en las columnas 3 a 7 de la Tabla 3.
h) Probar la generalización del MERNA. Para determinar la eficiencia en el RP del modelo sobre un nuevo conjunto de vectores reales se obtuvieron 200 nuevos vectores con patrones desconocidos, provenientes del caso industrial. Se corrió el modelo con los valores de entrenamiento obtenidos en la época 5. Posteriormente, se evaluaron estos nuevos vectores "fuera de línea" y se clasificaron por expertos para comparar los resultados obtenidos por el MERNA con lo diagnosticado "fuera de línea". El porcentaje de coincidencia se muestra en la columna 8 de la Tabla 3.

4. CONCLUSIONES

Para el caso de los GC multivariantes convencionales suele solicitarse la demostración de la normalidad tanto en X_1 y X_2 como en **X** como un supuesto estadístico requerido; se señala que para el modelo mostrado en este artículo tal demostración no es solicitada, pero si es empleada a manera de la aplicación de un criterio inicial que facilita el procesamiento de la información por los clasificadores del MERNA.

No ha sido posible demostrar que una RNA por sí misma pueda reconocer patrones multivariantes como tampoco se ha encontrado información en la literatura que permita afirmarlo. Por ello, en esta investigación se concluye que un conjunto de RNA interconectadas entre sí pueden ofrecer un avance importante en la solución del problema del RP multivariantes, tal como se ha observado en investigaciones relacionadas.

Si bien una BDI con datos obtenidos por simulación de Montecarlo permite teorizar y dar buenas soluciones teóricas al problema planteado, se observó que esta base no permite generalizar a casos reales lo cual supone que en los vectores de datos reales existen condiciones de tendencia, dispersión y forma que los modelos de Montecarlo clásicos empleados en este tipo de investigaciones no pueden reproducir.

Para esta investigación se emplearon las estadísticas descriptivas de tendencia central y de dispersión como señales de entrada. Se comenta que para optar por estos estadísticos se realizaron experimentos con otro tipo de señales de entrada que no se mues-

Clasificador	BDI (1)	BDM (2)	BDM época 1 (3)	BDM época 2 (4)	BDM época 3 (5)	BDM época 4 (6)	BDM época 5 (7)	Comparación MERNA-Expertos (8)
I	100% *Sobre 50 vectores*	78% *Sobre 104 vectores*	100%	100%	100%	100%	100%	100 % *Sobre 25 nuevos vectores*
II	71% *Sobre 50 vectores*	53% *Sobre 128 vectores*	73.3%	77%	81%	84%	84.5%	82 % *Sobre 30 nuevos vectores*
III	100% *Sobre 50 vectores*	77% *Sobre 125 vectores*	100%	100%	100%	100%	100%	100 % *Sobre 30 nuevos vectores*
IV	68% *Sobre 50 vectores*	50% *Sobre 78 vectores*	75%	76%	82%	89%	89.2%	75 % *Sobre 45 nuevos vectores*
V	100% *Sobre 50 vectores*	70% *Sobre 58 vectores*	100%	100%	100%	100%	100%	100 % *Sobre 35 nuevos vectores*
VI	60% *Sobre 50 vectores*	50% *Sobre 57 vectores*	59%	68%	75%	77%	77.5%	70 % *Sobre 35 nuevos vectores*

Tabla 3: Eficiencia en el RP del MERNA

tran en el artículo, pero se afirma que tanto la tendencia central como la dispersión producen los mejores resultados del RP multivariantes. Entre otros estadísticos probados están la matriz de covarianza, coeficientes de correlación, modas y medianas.

El modelo mostrado en esta investigación debe ser acompañado con el juicio y análisis de los expertos por un periodo de prueba considerable para ser implementado totalmente en línea, debiendo los expertos tener conocimiento en inteligencia artificial para obtener BDM adecuadas a los procesos industriales de aplicación. Al parecer lo afirmado por [29] sobre el problema de búsqueda de estructuras en BD para el RP está vigente. Bezdek expresó que son necesarias tres técnicas para atender este problema: experiencia en el proceso con examinación visual, técnicas estadísticas e inteligencia artificial. Si bien, estas tres pueden emplearse unas sin las otras, para esta investigación es claro que el uso simultáneo de las tres ofrece la mejor garantía de avanzar adecuadamente en el problema de RP.

El MERNA presentado en este artículo está probado para la identificación de patrones bivariantes conformados por la combinación de los 5 patrones encontrados en el caso industrial. Un enfoque altamente interesante de ampliación de posibilidades de este método resulta en la generalización de $n = 2$ a $n > 2$, con lo cual los autores reflexionan comentando los aspectos a considerar en esta tarea. Primero, se debe entender que el crecimiento exponencial de casos combinatorios hará más grande al espacio muestral y a la población de estudio, esto es, la Fig. (3) tendrá por ejemplo para $n = 3$, la forma de un cubo y los cuadros de las combinaciones ahora tendrían profundidad para incluir a la tercera variable; esto significa que los casos multivariantes se incrementarán de manera acelerada conforme n crece. Otro aspecto importante será que los tamaños de los vectores de medias y desviaciones estándar y, por ende, las señales de entrada al MERNA también crecerá al mismo tamaño de n, pero ello no modificará a la longitud del vector de salida pues estaría siempre indicado casos de combinaciones de patrones, aunque si, como se dijo, la cantidad de los puntos muestrales y poblacionales de estudio.

Finalmente, y sin duda el concepto más relevante a analizar en la ampliación a más de dos variables en el MERNA, es "la paradoja de la dimensionalidad" o efecto Hughes [30] donde se establece que la dimensionalidad creciente disminuye la fiabilidad de las estimaciones de los parámetros estadísticos. Este efecto se puede observar en diversos campos de estudio de las ciencias como la estadística, matemáticas y por supuesto el aprendizaje inteligente. Entonces, no se podrá omitir este efecto y un escenario esperado es el decremento en la eficiencia del MERNA al menos en etapas primarias de entrenamiento. La manera de abordar este efecto conlleva a razonar en mejorar la calidad de las BDI y BDM y para valores grandes de n tal vez, emplear distintos algoritmos de entrenamiento como topologías de RNA.

REFERENCIAS

1. Hernandez-Lopez A, Vazquez-Lopez JA, Lopez-Juarez I, Lefranc G (2015) Pattern recognition in multivariate statistical process control for dimensional transformation of statistical parameters. In: 2015 CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON). IEEE, pp 19–24
2. Levy Mangin J-P, Vargas Vargas M, Alfaro Navarro JL, Mondejar Jimenez J (2010) Graficos multivariantes aplicados al control estadístico de la calidad. Netbiblo
3. Bartes A, Llabres XTM (2004) Métodos estadísticos. Control y Mejora de la Calidad. Barcelona: Alfaomega, Catalunya
4. Guh R-S (2005) Real-time pattern recognition in statistical process control: A hybrid neural network/decision tree-based approach. Proc Inst Mech Eng Part B J Eng Manuf 219:283–298. doi: https://doi.org/10.1243/095440505X28963.
5. Vazquez-Lopez J.A., Lopez-Juarez I. (2009) SPC without Control Limits and Normality Assumption: A New Method. In: Bayro-Corrochano E., Eklundh JO. (eds) Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications. CIARP 2009. Lecture Notes in Computer Science, vol 5856. Springer, Berlin, Heidelberg.
6. Pamela C-S, Ismael L-J, José Antonio V-L (2014) Reconocimiento de variables multivariantes empleando el estadístico T2 Hotelling y MEWMA mediante las RNA's. Ing Investig y Tecnol 15:125–138. doi: https://doi.org/10.1016/S1405-7743(15)30011-1
7. Ruelas Santoyo E A, et al (2017) Sistema para el Monitoreo y Control de Procesos Multivariantes a través del Estadístico T2 de Hotelling y la Red Neuronal Artificial Fuzzy ARTMAP. Dyna Manag 5:[12 p.]-[12 p.]. doi: https://doi.org/10.6036/MN8206
8. Hachicha W, Ghorbel A (2012) A survey of control-chart pattern-recognition literature (1991–2010) based on a new conceptual classification scheme. Comput Ind Eng 63:204–222. doi: https://doi.org/10.1016/j.cie.2012.03.002
9. Masood I, Hassan A (2014) Expert Systems with Applications Bivariate quality control using two-stage intelligent monitoring scheme. Expert Syst Appl. doi: https://doi.org/10.1016/j.eswa.2014.05.042
10. Yu J, Xi L (2007) A Neural Network Ensemble for Classifying Source(s) in Multivariate Manufacturing Processes. 1246–1250
11. Bersimis S (2017) Methods for interpreting the out-of-control signal of multivariate control charts: A comparison study. 2295–2326. doi: https://doi.org/10.1002/qre.2191
12. Hotteling H (1947) Multivariate quality control ilustrated by the air testing of sample bombsights. In: Eisenhart M, Hastay W, Wallis W (eds) Techniques of statistical analysis. Mc Graw Hill, New York, pp 11–184
13. Lowry CA, Woodall WH, Champ CW, Rigdon SE (1992) A Multivariate Exponentially Weighted Moving Average Control Chart. Technometrics 34:46. doi: https://doi.org/10.2307/1269551
14. Crosier RB (1988) Multivariate Generalizations of Cumulative Sum Quality-Control Schemes. Technometrics 30:291–303. doi: https://doi.org/10.1080/00401706.1988.10488402
15. Masood I, Hassan A (2010) Issues in development of artificial neural network-based control chart pattern recognition schemes. Eur J Sci Res 39:336–355
16. Zorriassatine F, Tannock JDT (1998) A review of neural networks for statistical process control. J Intell Manuf 9:209–224
17. Zorriassatine F, Al-Habaibeh A, Parkin RM, et al (2005) Novelty detection for practical pattern recognition in condition monitoring of multivariate processes: a case study. Int J Adv Manuf Technol 25:954–963. doi: https://doi.org/10.1007/s00170-004-2174-8
18. Yu J, Xi L (2009) A neural network ensemble-based model for on-line monitoring and diagnosis of out-of-control signals in multivariate manufacturing processes. Expert Syst Appl 36:909–921. doi: https://doi.org/10.1016/j.eswa.2007.10.003
19. Yu J, Xi L, Zhou X (2009) Identifying source(s) of out-of-control signals in multivariate manufacturing processes using selective neural network ensemble. Eng Appl Artif Intell 22:141–152. doi: https://doi.org/10.1016/j.engappai.2008.05.009
20. Hwarng H (1992) Pattern recognition on Shewhart control chart using a Neural Network approach. Arizona State Univ.
21. Cheng C-S (1997) A neural network approach for the analysis of control chart patterns. Int J Prod Res 35:667–697. doi: https://doi.org/10.1080/002075497195650
22. Pugh GA (1989) Synthetic neural networks for process control. Comput Ind Eng 17:24–26. doi: https://doi.org/10.1016/0360-8352(89)90030-2
23. Pham DT, Liu X (1995) Neural Networks for Identification, Prediction and Control. Springer London, London
24. Pacella M, Semeraro Q, Anglani A (2004) Manufacturing quality control by means of a Fuzzy ART network trained on natural process data. Eng Appl Artif Intell 17:83–96. doi: https://doi.org/10.1016/j.engappai.2003.11.005
25. El-Midany TT, El-Baz MA, Abd-Elwahed MS (2010) A proposed framework for control chart pattern recognition in multivariate process using artificial neural networks. Expert Syst Appl 37:1035–1042. doi: https://doi.org/10.1016/j.eswa.2009.05.092
26. Zobel * CW, Cook DF, Nottingham QJ (2004) An augmented neural network classification approach to detecting mean shifts in correlated manufacturing process parameters. Int J Prod Res 42:741–758. doi: https://doi.org/10.1080/00207540310001602856
27. - ZB, - LF, - LS (2012) A Hybrid Svm Model for On-Line Monitoring And Diagnosing Mean Shifts In Multivariate Processes. J Converg Inf Technol 7:102–114. doi: https://doi.org/10.4156/jcit.vol7.issue23.13
28. Yu J, Zheng X, Wang S (2019) Stacked denoising autoencoder - based feature learning for out - of - control source recognition in multivariate manufacturing process. 204–223. doi: https://doi.org/10.1002/qre.2392
29. Bezdek JC (1981) Pattern Recognition with Fuzzy Objective Function Algorithms. Springer US, Boston, MA
30. Hughes GF (1968) On the mean accuracy of statistical pattern recognizers. IEEE Trans Inf Theory 14:55–63.

AGRADECIMIENTOS

Los autores agradecen al consejo nacional de ciencia y tecnología (CONACYT), el apoyo recibido en la formación doctoral de la M.C. Aideé Hernández López.