

Uso de la red neuronal Perceptrón para detección de cambios pequeños en la media en los gráficos de control.

Paloma Teresita Gutiérrez-Rosas

Instituto Tecnológico de Celaya, Celaya, Guanajuato, México, palomagt89@hotmail.com

José Antonio Vázquez-López

Instituto Tecnológico de Celaya, Celaya, Guanajuato, México, antonio.vazquez@itcelaya.edu.mx

Manuel Darío Hernández-Ripalda

Instituto Tecnológico de Celaya, Celaya, Guanajuato, México, buzonmdhr@yahoo.com.mx

Salvador Hernández-González

Instituto Tecnológico de Celaya, Celaya, Guanajuato, México, salvador.hernandez@itcelaya.edu.mx

Ismael López-Juárez

Centro de Investigación y de Estudios Avanzados del IPN, Saltillo, Coahuila, México,
ismael.lopez@cinvestav.edu.mx

RESUMEN

En esta investigación se aplicó la red neuronal artificial Perceptrón a fin de determinar su capacidad de detección del patrón de variación especial denominado “cambio superior en la media”. Este patrón se presenta regularmente en los gráficos de control de Shewhart. La detección de dicho patrón es de gran importancia, pues indica un estado fuera de control estadístico en los procesos de manufactura, por tanto es fundamental su pronta detección para tomar de decisiones inmediatas para corregir y restablecer la calidad en el proceso. Se midió la eficiencia de tal red neuronal artificial para una amplia gama de valores de cambios en la media, cubriendo lo estadísticamente conocido como “cambios pequeños” y “cambios grandes”. Se destaca esto porque los gráficos de control de Shewhart no sirven para cambios pequeños, por lo que la propuesta del uso de la red neuronal artificial como agente identificador de este tipo de cambio constituye una contribución importante de esta investigación.

Palabras clave: Perceptrón, Gráficos de control, Control estadístico de calidad, Reconocimiento de patrones, Cambio en la media.

ABSTRACT

This research applied the Perceptron artificial neural network to recognize the special variation pattern called "upward shift". This pattern appears regularly in Shewhart control charts. The detection of this pattern is of great importance as it indicates an out of statistical control of manufacturing processes. Therefore rapid detection is essential to take immediate corrective and preventive decisions. Recognition efficiency was measured across a wide range of changing vales of the mean. In this way, "small changes" and "large changes" in the level of the mean are considered. This is emphasized because the Shewhart control charts are not good for small changes, so that the proposed use of artificial neural network identifier as an agent of such change constitutes a major contribution of this research.

Keys words: Perceptron, Control charts, Statistical process control, Pattern recognition, Upward shift pattern.

1. INTRODUCCIÓN

Una serie de datos numéricos obtenida 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.

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.

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 función de la combinación de sus características estadísticas. Esta investigación trata sobre la identificación de uno de los patrones de inestabilidad comúnmente presentados, sin usar GC y empleando la Red Neuronal Artificial Perceptrón por sus habilidades como máquina clasificadora.

La Perceptrón, creada en la década de 1950, resultó satisfactoria para ser usada como sistema clasificador de problemas linealmente separables. Es de fácil entendimiento y manipulación y permite procesar grandes cantidades de datos en tiempo real, además de que permite expresar su salida en código binario, lo que ayuda cuando se usa a esta red como un módulo de intercomunicación con otros programas de cómputo.

Se presenta al espacio gráfico del GC como el plano donde se trazarán los hiperplanos generados por las neuronas de la Perceptrón para establecer áreas de ubicación de distintos niveles del valor de la media de series numéricas.

Considerando a la introducción, este artículo está dividido en 6 secciones tal como se indica a continuación: I. Introducción: se describe brevemente el uso de los gráficos de control y la forma en que estos operan, así como también se muestra de forma general el enfoque de la red neuronal artificial Perceptrón, como clasificador; en la sección II, se muestra a esta red neuronal de forma explícita y se indica el patrón especial bajo estudio en el artículo; en la parte tres, se aborda la metodología de investigación empleada; en la parte cuatro se muestran los resultados obtenidos al analizar series numéricas generadas por simulación, para calcular el error de selección del patrón de la red a grandes cantidades de datos; la sección cinco incluye la validación de la propuesta establecida en este artículo, de usar a la Perceptrón como sistema de identificación del patrón especial “cambio en la media”, en

una base de datos obtenida de un proceso de selección de un producto alimenticio basándose en una propiedad física de este. Finalmente, la sección seis incluye las conclusiones derivadas de este estudio y el trabajo futuro.

2. RED NEURONAL ARTIFICIAL Y PATRÓN ESPECIAL DE VARIACIÓN

El área de aplicación más importante de las redes neuronales artificiales (RNA) es el reconocimiento de patrones, razón por la cual las RNA son aplicables en los métodos de control de calidad de procesos productivos, visto esto como una posible solución al problema de detección de patrones en los gráficos de control (Stoumbos, Reynolds, Ryan, & Woodall, 2000) tanto en cambios pequeños como en cambios grandes en el valor de la media. Es conocido que para la interpretación y análisis de un gráfico de control existen diversas reglas universales desarrolladas para intentar reconocer patrones de variación no natural, (Western Electric, 1956) (Nelson, 1984) sin embargo, los gráficos de control no fueron diseñados con el propósito del reconocimiento de patrones. La presente investigación se enfocó en el caso donde existe un cambio superior en la media (μ) que se presenta en una serie de datos, lo que se interpreta como un patrón indicador de un estado de fuera de control estadístico de calidad asumiendo la presencia de causas especiales de variación.

Se eligió a la RNA Perceptrón por adecuarse con simplicidad a las necesidades de clasificación en dos categorías o más, lo cual es requerido para esta investigación. Se entrenó a la red neuronal Perceptrón con el objetivo de observar si esta red presenta la capacidad para detectar el patrón referido. En el patrón de cambio superior en la media, la serie se divide en dos partes, donde sus medias son μ_1 y μ_2 , de tal forma que $\mu_1 < \mu_2$ y $d = \mu_2 - \mu_1$ es conocida como el cambio de la media del proceso. La expresión

$$x_t = \mu + n_t + d \quad (1)$$

sirve para explicar el patrón de cambio superior en la media si el vector $\mathbf{x} = [x_1, x_2, \dots, x_n]$ es una serie temporal que contiene dos poblaciones de datos, \mathbf{x}_1 y \mathbf{x}_2 , donde $\mathbf{x}_1 = [x_1, x_2, \dots, x_p]$ y $\mathbf{x}_2 = [x_{p+1}, x_{p+2}, \dots, x_n]$ para $p < n$, de tal forma que $(\mathbf{x}_1 \cup \mathbf{x}_2) = \mathbf{x}$. Así, $\mathbf{x}_1 \sim N(\mu_1, \sigma)$ cuando en un valor “ $t = p$ ”, donde $0 < p < n$, ocurre un cambio de magnitud “ d ” en los valores sucesivos de \mathbf{x} haciendo que se genere la población de datos de \mathbf{x}_2 , donde $\mathbf{x}_2 \sim N(\mu_2, \sigma)$ bajo la condición que $\mu_1 < \mu_2$, tal como se muestra en la figura 1.




Figura 1. Representación esquemática del patrón cambio superior en la media (Hagan, Demuth, & Beale, 1996).

Una red neuronal consiste en un número de elementos (nodos) fuertemente interconectados que tienen la habilidad de procesar información como resultado de un proceso de trabajo dinámico de esos nodos y de conexiones a puntos externos a la red. La primera aplicación de las redes neuronales artificiales fue a finales de la década de 1950, con la invención de la red Perceptrón y la regla de aprendizaje de asociación hecha por Frank Rosenblatt, quien junto a sus colegas demostraron la habilidad de la red Perceptrón para el reconocimiento de patrones. Dichos sucesos generaron gran interés en la investigación de redes neuronales. Para mayor información sobre la historia y evolución de las redes neuronales artificiales durante su etapa de desarrollo inicial, ver Hagan, Demuth, & Beale (1996). En las últimas décadas, cientos de documentos han sido escritos y desarrollados y se le han encontrado muchas aplicaciones a las redes neuronales. Muchos de los avances en las redes neuronales han tenido que ver con el desarrollo de nuevos conceptos, como por ejemplo arquitecturas innovadoras y reglas de

entrenamiento. De igual magnitud de importancia ha sido la capacidad de las poderosas nuevas computadoras en las cuales se ponen a prueba dichos nuevos conceptos.

En la revisión de la literatura se ha encontrado que diversos investigadores sugieren el uso de redes neuronales como una manera de trabajar el control estadístico de procesos, conociendo las desventajas en el uso de las técnicas de control tradicionales. Wafik, H. & Ahmed, G. (2012) presentan una extensa revisión de la literatura en este sentido, durante el periodo de 1991 a 2010. La importancia señalada en el uso de las redes neuronales se describe mediante sus principales ventajas sobre las técnicas de control estadístico basadas en gráficos de control (Guh, 2005), siendo estas, entre otras las siguientes:

- a) Las redes neuronales empleadas con el fin del reconocimiento de patrones estadísticos de los datos permiten fácilmente reconocer, en tiempo-real, distribuciones no normales con rapidez y eficiencia elevadas, especialmente cuando la distribución presenta sesgos (Guh, 2005).
- b) El uso de las redes neuronales no requiere del supuesto de normalidad en los datos o de la independencia de los mismos (Pacela, Semeraro y Anglania, 2004).
- c) Las RNA han tenido aplicación diversa en el campo de la estadística, especialmente cuando se requiere manejar una gran cantidad de datos en tiempo-real que presentan cierta complejidad.

Una neurona de entrada unitaria es mostrada en la figura 2. El escalar de entrada p es multiplicado por el escalar nombrado peso w , para formar wp , dicho termino es enviado a la sumatoria. La otra entrada l , es multiplicada por un valor nombrado bias b y después pasa a la sumatoria. En la sumatoria la salida es nombrada como n , la cual viaja hacia la función de transferencia f , la cual produce el escalar de salida de la neurona a . Se puede entender así la correspondencia que existe entre su contraparte biológica, las dendritas conllevan la nueva señal de entrada p hasta el cuerpo de la neurona, donde se realiza la sumatoria de elementos, y su transformación específica con respecto a la función de transferencia utilizada y por último se transmite como una señal de salida ya sea al exterior o hacia otra neurona a través de lo que representaría el axón.

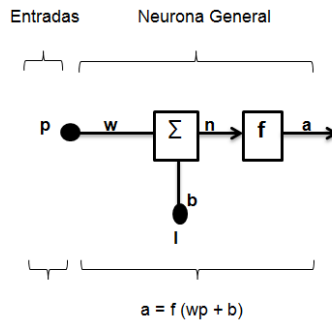


Figura 2. Representación de una neurona de entrada unitaria (Hagan, Demuth, & Beale, 1996).

La salida de la neurona es calculada como:

$$a = f(wp + b)$$

El valor de la salida depende en particular de la función de transferencia elegida y tanto w como b son parámetros escalares ajustables de la neurona. Típicamente la función de transferencia es elegida por el diseñador y después los parámetros w y b serán ajustados por alguna regla de aprendizaje que se relacione con la entrada y salida de la neurona en busca de un valor meta específico para cada uno. Existen varios tipos de funciones de transferencia, siendo la función de transferencia Hard limit la empleada en esta investigación, la cual es mostrada en la figura 3. La salida de la neurona será cero si el argumento de la función es menor que 0, ó la salida será 1 si su argumento es mayor o igual a cero. Esta función de transferencia es usada para crear neuronas que clasifiquen entradas en dos diferentes categorías.




Figura 3. Representación gráfica de la función de transferencia Hardlim o Hard limit (Hagan, Demuth, & Beale, 1996).

La figura 3 ilustra las salidas típicas de una neurona con una sola entrada que usa la función de transferencia Hard Limit. Es posible observar el efecto del peso y la compensación, también se muestra el icono representativo de la función de transferencia. Asociada al caso del artículo, es útil tener valores 0 y 1 como salidas de la red, ya que hay que asociar el 1 con el momento en que se detecte un patrón especial y 0 cuando esto no sea así.

Entradas Neurona con múltiples entradas

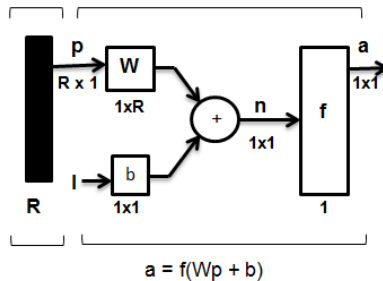


Figura 4. Notación gráfica abreviada de una neurona con R entradas. (Hagan, Demuth, & Beale, 1996).

La figura 4 muestra la notación abreviada de una neurona como la anterior, pero con respecto a múltiples entradas que corresponderán a un vector de tamaño $R \times 1$, como se ilustra en la figura 5.

Entradas Capa con función Hard limit

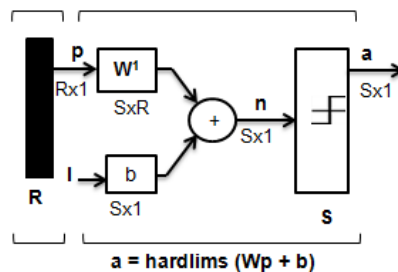


Figura 5. Notación abreviada de la estructura de una red neuronal Perceptrón con una sola capa con función de transferencia Hardlim (Hagan, Demuth, & Beale, 1996).

Una red neuronal Perceptrón de una neurona, como la que se muestra en la figura 2, puede clasificar un vector de entrada en dos categorías. -1 ó 1. Así, si el producto interno de la matriz de pesos con el vector de entrada es mayor o igual que $-b$, la salida será 1, si el producto interno de la matriz de pesos con el vector de entrada es menor que $-b$ el resultado será -1. Esto divide el espacio de entrada en dos partes como se ilustra en la figura 6 para $b=-1$, a lo cual se le conoce como límite de decisión.




Figura 6. Límite de decisión de una red neuronal Perceptrón
(Hagan, Demuth, & Beale, 1996).

En la figura 6 es posible observar que el límite de decisión siempre será ortogonal a la matriz de pesos, y la posición del límite puede ser cambiado si se cambia el valor de b . La característica clave de la Perceptrón de una sola neurona, es que puede separar vectores de entrada en dos categorías. El límite de decisión entre las categorías es determinado mediante la ecuación $Wp + b = 0$.

3. METODOLOGÍA

El entrenamiento de redes neuronales artificiales en Matlab (The Mathworks Inc., 2010) se lleva a cabo con una herramienta específica del mismo nombrada Interfaz Gráfica, en la cual el usuario debe identificar las características de la red a utilizar, comenzando con el tipo de red. Para el presente estudio se utilizó la red neuronal artificial Perceptrón, la función de transferencia que utilizará la red, en este caso Hardlim y por último la función de aprendizaje de la red, en este caso titulado Learnp. Se pueden emplear otras formas de entrenamiento y aparentemente su elección es arbitraria, seleccionando aquellas con menores tiempos de convergencia o menor nivel de error de clasificación. Para consultar estos métodos véase Theodoridis y Koutroumbas (2009).

Para comenzar con el algoritmo de entrenamiento de la red ya identificada es necesario introducir vectores de datos que representen los patrones de comportamiento que la red debe ser capaz de clasificar, así como el valor con el cual es deseable que la red los identifique, para ello se creó una base de datos que representaría el proceso en un estado óptimo para el cual se definieron los valores de los parámetros de media y la desviación estándar en $\mu_1 = 0$ y $\sigma = 1$, correspondiente a x_1 . Por su parte, para x_2 , $\mu_2 = d$ y $\sigma = 1$ y $n = 10$. Una vez que se tuvieron los datos a ingresar a la red para su identificación, se introdujo junto con ellos el valor objetivo con el cual se desea sean clasificados, en este caso para que clasificara con un valor de cero 0 a los datos que siguen las características del proceso óptimo (x_1) y con un valor de 1 a los datos que siguen las características del patrón de aumento en la media (x_2).

El software por sí mismo realiza las iteraciones necesarias hasta que la red neuronal artificial Peceptron obtiene los valores para los pesos y bias que realizan de forma correcta la clasificación de los datos introducidos, es posible que el usuario visualice dichos valores por lo cual se verificó por medio de programación que la red neuronal Perceptrón con los valores obtenidos durante el entrenamiento es capaz de clasificar de forma correcta los vectores de datos correspondientes. En las ocasiones que se realizó esta prueba la red neuronal Perceptrón clasificó de forma correcta los datos, esto se consideró como un primer indicio acerca de que la red neuronal Perceptrón es capaz de reconocer el patrón de aumento en la media.

Para determinar de forma precisa la magnitud en la cual la red es capaz de clasificar el patrón mencionado con éxito, se realizó el mismo procedimiento descrito contemplando algunas variaciones en los datos con los cuales se llevó a cabo el entrenamiento, comenzando con disminuir la diferencia existente entre medias hasta 0.1 unidades a fin de determinar si existen valores para los pesos y bias de la red que puedan diferenciar dicho aumento en la media.

De lo anterior se obtuvieron, valores diferentes para los pesos y bias de la red, de los obtenidos en un inicio; para obtener conclusiones contundentes se programaron los nuevos valores de la red y en 10,000 ocasiones se evaluaron con 10,000 vectores de datos diferentes pero que presentaban el mismo nivel de aumento en la media $\mu_2 = 2$, a fin de determinar que tan certera es la clasificación de la red neuronal ante este nivel de cambio.

Las mismas 10,000 repeticiones se realizaron con aumentos en la media cada vez más pequeños, disminuyendoles en intervalos de 0.1 unidades, para verificar si la red presenta la misma eficiencia de detección con todos los tipos de datos o si a partir de cierto nivel comienza a disminuir o aumentar la eficiencia de su detección con respecto al patrón. Del procedimiento anterior se obtuvo el porcentaje de errores que presentó la red al realizar la clasificación para cada uno de los diferentes niveles de aumento en la media de los datos. Es decir el porcentaje de las ocasiones que la red arrojó un valor respuesta de (0), indicando que el cambio superior en la media no existía, cuando en realidad si se estaba presentando y el valor respuesta que debería haber arrojado correspondía a un (1).

4. RESULTADOS POR SIMULACIÓN

Para el experimento realizado con $n=10$, se obtuvieron los porcentajes de error de las 10,000 corridas para cada uno de los diferentes intervalos de aumentos en la media de los datos, obteniendo resultados como los que se presentan en la tabla 1, en la cual se indica en las columnas tituladas nivel de cambio, el valor d , a dichos valores le corresponde un porcentaje de error que presentó la red durante la experimentación, el cual se localiza a la derecha de cada valor en las columnas tituladas como Error (%).

Tabla 1. Porcentaje de errores presentados en la clasificación de la red neuronal Perceptrón con diferentes niveles de cambio superior en la media.

d	Error (%)	d	Error (%)	d	Error (%)	d	Error (%)	d	Error (%)
0.8	1.95	1.03	0.42	1.26	0.04	1.49	0	1.72	0.01
0.81	1.7	1.04	0.36	1.27	0.04	1.5	0	1.73	0
0.82	1.57	1.05	0.38	1.28	0.06	1.51	0	1.74	0
0.83	1.65	1.06	0.33	1.29	0.03	1.52	0	1.75	0
0.84	1.64	1.07	0.34	1.3	0.05	1.53	0	1.76	0
0.85	1.45	1.08	0.26	1.31	0.07	1.54	0	1.77	0
0.86	1.48	1.09	0.19	1.32	0.01	1.55	0	1.78	0
0.87	1.25	1.1	0.26	1.33	0.06	1.56	0	1.79	0
0.88	1.24	1.11	0.15	1.34	0.02	1.57	0	1.8	0
0.89	1.21	1.12	0.27	1.35	0.01	1.58	0	1.81	0
0.9	0.91	1.13	0.24	1.36	0.03	1.59	0.01	1.82	0
0.91	1.14	1.14	0.14	1.37	0.03	1.6	0	1.83	0
0.92	0.84	1.15	0.14	1.38	0.02	1.61	0	1.84	0
0.93	0.83	1.16	0.14	1.39	0.01	1.62	0	1.85	0
0.94	0.64	1.17	0.21	1.4	0.01	1.63	0	1.86	0
0.95	0.77	1.18	0.12	1.41	0.02	1.64	0	1.87	0
0.96	0.63	1.19	0.07	1.42	0.02	1.65	0	1.88	0
0.97	0.57	1.2	0.11	1.43	0.02	1.66	0.01	1.89	0
0.98	0.54	1.21	0.12	1.44	0.02	1.67	0	1.9	0
0.99	0.44	1.22	0.07	1.45	0	1.68	0	1.91	0
1	0.51	1.23	0.05	1.46	0.03	1.69	0	1.92	0
1.01	0.45	1.24	0.08	1.47	0.03	1.7	0	1.93	0

Para visualizar dichos resultados de la tabla 1 se realizó la figura 7, a fin de determinar el comportamiento que representa el porcentaje de errores detectado según el valor d .




Figura 7. Gráfico del porcentaje de errores presentados en la clasificación de la red neuronal Perceptrón con diferentes niveles de aumento en la media para n=10.

En la figura 7 se observa que el porcentaje de error que se obtiene con la red neuronal Perceptrón después de su entrenamiento es cada vez más pequeño, presentando un comportamiento asintótico en un nivel cero, a medida que el valor d aumenta, haciendo más diferenciable al patrón.

5. VALIDACIÓN

Se probó el método propuesto con una base datos numérica obtenida de un proceso de medición de la longitud, expresada en centímetros, de un producto alimenticio, fruto de la planta *Solanum lycopersicum*, llamado **tomate** (o **jitomate** en el centro de México), producido en un invernadero cuya supervisión de la longitud es un proceso importante de control de calidad. La base de datos cuenta con 500 registros útiles, de cuyo análisis estadístico se obtiene que la longitud es una variable aleatoria distribuida conforme a una normal, que presenta cambios en el nivel de la media moderados, en grupos de diferentes cantidades de elementos, sin que ello afecte a la normalidad de los mismos, dado el bajo nivel del cambio.

Para secuencias de 10 mediciones se aplicó el método propuesto para evaluar si la media de tal secuencia había tenido cambio pequeño en el nivel de la media, de forma independiente al valor de la desviación estándar. El valor de la media poblacional de la longitud se estima en 6 cm y la desviación estándar en 0.7cm. Los valores extremo localizados en la serie de los 500 registros fueron 4.6cm y 7.4cm y se dividió este intervalo en 16 sub intervalos de 0.175 cm de amplitud, cantidad que corresponde una cuarta parte de la desviación estándar, para observar cambios pequeños.

En total se procesaron 50 series numéricas de 10 elementos cada una (500 datos de la serie entre 10 elementos de cada serie) para evaluar 50 medias con cambios potenciales. Se estableció el intervalo (5.825cm, 6.175cm) como el adecuado para el proceso donde no es significativo el cambio en el nivel de la media. La tabla 2 muestra los resultados obtenidos. De forma global, se reconocieron correctamente el 94% de las 50 series, considerando como elemento de juicio al proceso estadístico de prueba de hipótesis con un nivel de confianza del 95%, probando la hipótesis nula del valor de la media a partir de la serie numérica obtenida.

Los porcentajes de error de clasificación mostrados en la tabla 2 no tienen explicación demostrable ya que esto fue obtenido de datos que no fueron replicados por métodos de simulación, teniendo en consecuencia, sólo el juicio de la experiencia derivada del proceso de inspección del producto, para decidir si los falsos positivos se deben en si al método de reconocimiento de patrones por la Perceptrón, o al error aleatorio natural, lo cual deberá ser investigado.

Tabla 2. Detección de cambios en el nivel de la media en la observación de la longitud del producto empleado para validar el método

<i>d</i>	-0.7cm	-0.35cm	0cm	0.35cm	0.525cm	0.7cm	1.05cm	1.225cm
Valor de la media	5.51 cm	5.755cm	6.0cm	6.245cm	6.37cm	6.49cm	6.735cm	6.86cm
Casos	2	3	11	7	4	7	7	9
Falsos positivos	0	0	1	1	0	0	0	1
Clasificaciones correctas	2	3	10	6	4	7	7	8
Porcentaje de error	0.0%	0.0%	9.0%	14.2%	0.0%	0.0%	0.0%	11.1%

La arquitectura empleada en esta validación corresponde a la mostrada en la figura 5, para los valores siguientes:

$R = 1$ entradas a la red, que es la media de la serie de diez elementos.

$S = 17$ neuronas, asociadas a las 16 sub divisiones del intervalo de variación de la longitud del producto.

De este modo, p es un escalar, \mathbf{W} es una matriz de 17×1 , \mathbf{b} es un vector de 17×1 , \mathbf{n} es un vector de 17×1 y \mathbf{a} es un vector de 17×1 .

6. CONCLUSIONES

La red neuronal Perceptrón es capaz de detectar y clasificar de manera correcta el patrón de aumento en la media de una serie de datos si previamente se le entrena con datos que presenten y no presenten el patrón a identificar, en diversas magnitudes y de preferencias con aumentos pequeños del considerado valor ideal en la media.

Es necesario, para su aplicación, un cambio de enfoque de la forma de entendimiento de los gráficos de control, pues bajo el uso de redes neuronales artificiales se debe poner atención en el entrenamiento de la red, para la identificación de los patrones de interés, mientras que en los gráficos de control, el interés se centra en entrenar al personal para que los reconozca.

La literatura no reporta casos de aplicación de la Perceptrón como un método de reconocimiento de patrones de uso industrial, sólo indica que su uso es factible y de buen pronóstico en base a resultados experimentales y datos obtenidos por procesos de generación de números aleatorios, con esta y otras redes neuronales artificiales. De cualquier forma, esta como otras investigaciones, apuntan al uso de las redes neuronales artificiales como manera de inspección de la variación de las variables aleatorias en los procesos de producción, basado esto en la evidencia disponible.

Investigaciones próximas incluyen el uso de esta red neuronal artificial en esquemas multivariantes, para identificar estados de control y de no control del proceso.

REFERENCIAS

- Guh, R. S. (2005). "Real-time pattern recognition in statistical process control: a hybrid neural network/decision tree-based approach". IMechE, Part B: *J. Engineering Manufacture*, 219 (3), 283-298.
- Hagan, M. T., Demuth, H. B., & Beale, M. (1996). "Neural Network Design". U.S.A.: Thomson.
- Nelson, L. S. (1984). "Technical Aids". *Journal of Quality Technology*, 16 (4), 238-239.
- Pacela, M., Semeraro, Q., & Anglania, A. (2004). "Manufacturing Quality Control By Means Of A Fuzzy ART Network Trained On Natural Process Data". *Engineering Applications Of Artificial Intelligence*, 17, 83-96.
- Stoumbos, Z. G., Reynolds, M. R., Ryan, T. P., & Woodall, W. H. (2000). "The State of Statistical Process Control as We Proceed into the 21st Century". *Journal of the American Statistical Association*, 992-998.

Theodoridis, S. & Koutroumbas, K. (2009). Pattern Recognition. Canada: Academic Press.

The Mathworks Inc. (2010). MATLAB. Natick, MA.

Wafik, H. & Ahmed, G. (2012). A survey of control-chart pattern-recognition literature (1991-2010) based on a new conceptual classification scheme, Computers & Industrial Engineering.

Western Electric. (1956). *Statistical Quality Control Handbook*. Indianapolis, IN.: AT& T.

Autorización y Renuncia

Los autores autorizan a LACCEI para publicar el escrito en las memorias de la conferencia. LACCEI o los editores no son responsables ni por el contenido ni por las implicaciones de lo que esta expresado en el escrito.