

APLICACIÓN DE LA PERCEPTRÓN EN EL GRÁFICO DE CONTROL DE MEDICIONES INDIVIDUALES

*José Antonio Vázquez-López **Paloma Teresita Gutiérrez-Rosas
Armando J. Ríos-Lira *Luis Gerardo Esparza-Díaz

Recibido: 29/03/2012 Aprobado: 15/06/2012

Resumen

En este artículo se aplica la red neuronal artificial Perceptrón como sistema clasificador de puntos fuera de control en el ámbito de la carta de control de mediciones individuales. Se introduce el uso de las propiedades geométricas de la Perceptrón como método de entrenamiento para sustituir, en consecuencia, a los métodos de entrenamiento conocidos. Se experimentó con bases de datos numéricas contaminadas con datos alterados en su media global y se comparó la capacidad de la detección de puntos fuera de control de la carta de control con la aplicación de la Perceptrón entrenada por geometría. Los resultados revelan mayor capacidad en la Perceptrón en diferentes porcentajes de contaminación. Esta propuesta puede ser generalizada a otros tipos de gráficos de control y a patrones de variación especial y natural no considerados en esta investigación.

Palabras clave: Inteligencia artificial, Redes neuronales artificiales, Perceptrón, Gráficos de control, Control estadístico de calidad, Reconocimiento de patrones.

IMPLEMENTATION OF THE PERCEPTRON IN THE CONTROL CHART FOR INDIVIDUAL MEASUREMENTS

Abstract

In this article the Perceptron artificial neural network is applied as a classifier system of out of control points, in the field of control chart for individual measurements. The use of geometric properties of the Perceptron as a training method is introduced, replacing in consequence to the known training methods. Some experiments with numerical databases contaminated with altered data in global average was performed, and the ability of the detection of “out of control points” of the control chart with the implementation of the Perceptron trained by geometry was compared. The results reveal greater capacity in the Perceptron. This approach can be generalized to other types of control charts and patterns of natural and special variation, not considered in this research.

Keywords: Artificial intelligence, Artificial neural networks, Perceptron, Control charts, Statistical process control, Pattern recognition.

* *Departamento de Ingeniería Industrial, Instituto Tecnológico de Celaya, México, antonio.vazquez@itcelaya.edu.mx*

** *Departamento de Ingeniería Industrial, Estudiante de posgrado en Instituto Tecnológico de Celaya, México, palomagt89@hotmail.com*

*** *Departamento de Ingeniería Industrial, Instituto Tecnológico de Celaya, México, armando.rios@itcelaya.edu.mx*

**** *Departamento de Ingeniería Industrial, Instituto Tecnológico de Celaya, México, gesparza@itc.mx*

Introducción

En los gráficos de control de mediciones individuales, cada punto debe ser graficado y observado para determinar si el proceso de producción es estable. Este tipo de gráfico está indicado cuando el volumen de mediciones es bajo debido a diversas causas, tales como: proceso de producción lento, pruebas de calidad destructivas o pruebas de calidad en 3 laboratorios. Los gráficos de control han sido empleados exitosamente desde 1930 para detectar estabilidad (o inestabilidad) estadística provocada por causas naturales (o especiales) de variación. Recientemente han surgido investigaciones que proponen el uso de redes neuronales artificiales en el mismo ámbito que el de los gráficos. Wafik, H. & Ahmed, G. (2012) presentan una extensa revisión de la literatura en este sentido, durante el periodo de 1991 a 2010.

Es conocido que en los gráficos de control se requiere habilidad y experiencia humana para elaborar diagnósticos adecuados sobre la variación de los datos, lo que no es necesariamente requerido cuando se usan redes neuronales artificiales correctamente entrenadas. En consecuencia, las redes neuronales presentan ventajas sobre los gráficos de control (Guh, 2005; Zobel y Cook, 2004; Pacela et al., 2004).

Existen diferentes tipos de redes neuronales artificiales, destacando por su elevada eficiencia la Backpropagation (Guh, 2005) y FuzzyARTMAP (Vázquez et al., 2010). En estas investigaciones se abordan diferentes tipos de patrones de variación especial, pero no incluyen el patrón específico puntos fuera de control, el cual es considerado en el presente artículo, cuyo reconocimiento se presenta como un problema de clasificación por separación lineal de clases. Un antecedente específico de la Perceptrón en gráficos de control se puede ver en Gutierrez et al., (2011) quienes muestran a la red como un sistema de detección de cambios pequeños en la media de los datos de un proceso, considerando el rango de hasta 1.9 unidades de desviación estándar.

Sobre el uso de la Perceptrón como sistema clasificador de puntos fuera de control se responden en esta investigación las siguientes interrogantes: ¿detecta la Perceptrón más puntos fuera de control que el gráfico de control de mediciones individuales?, ¿a qué niveles de cambio en el valor de la media es más eficiente la Perceptrón que el gráfico de control? y finalmente, dados como rectas los límites de control del gráfico y su similitud con los hiperplanos de la Perceptrón, ¿es posible usar las bases geométricas de operación de la Perceptrón como punto de desarrollo de una forma de entrenamiento?

El entrenamiento de una red neuronal artificial debe conducir a la minimización del error de clasificación. Los procesos de entrenamiento típicos requieren dos bases de datos, conocidas como de entrenamiento y de prueba. La base de entrenamiento tiene la asociación de los datos a clasificar con la clase correcta, a diferencia de la base de prueba, que sólo contiene los puntos a clasificar. De forma general, entrenar a una red neuronal, y específicamente a la Perceptrón, consiste en localizar los parámetros de la ecuación 1 que minimicen el error de clasificación. El proceso de obtención de estos parámetros es conocido como entrenamiento y en este se deben considerar diversos aspectos, tales como el tamaño de la base de datos de entrenamiento para permitir la generalización (Duda et al., 2001) y la convergencia del algoritmo de entrenamiento (Bishop, 2008). Existen diferentes formas de entrenamiento de la Perceptrón, véase Theodoridis y Koutroumbas (2009), sin embargo todos tienen su origen en la característica geométrica de los componentes de la red, que en resumida cuenta, se explica por la formación de hiperplanos (representados y explicados como rectas en el plano cartesiano) en el espacio de clasificación.

Las propiedades geométricas de los hiperplanos descritos por la Perceptrón fundamentan la propuesta de este artículo que consiste en emplear la asociación de estos, con los límites de control del gráfico de control de mediciones individuales, dado que de ambos casos se puede afirmar que separan puntos en dos clases de datos, estos es, “puntos dentro de los límites de control” y “puntos fuera de los límites de control”, para el caso del gráfico de control, y “puntos por encima o por debajo del hiperplano considerado” para la Perceptrón. El desarrollo de esta idea produce la aportación descrita en este artículo, mismo que se presenta organizado como sigue: después de la introducción, se describen las generalidades y temas relevantes en la sección 2; la sección 3 contiene la asociación de la Perceptrón y los gráficos de control desde el enfoque geométrico para establecer el entrenamiento de la red e incluye el código empleado en MATLAB para la experimentación; posteriormente, la sección 4 presenta las pruebas y resultados obtenidos por la comparación del uso de la Perceptrón entrenada geoméricamente y el gráfico de control

de mediciones individuales y finalmente, la sección 5 muestra las conclusiones derivadas del estudio.

La red neuronal artificial Perceptrón

El problema de clasificación

Para una variable aleatoria denotada por X con m elementos en su espacio muestral, $X = \{x_1, x_2, \dots, x_m\}$, donde $n(X = x)$, o simplemente $n(x)$, sea una función de X , se tiene que por cada evaluación $X = x$ en $n(x)$ habrá una división de la recta X en dos partes y habrá en cada caso valores en X que sean superiores, iguales o inferiores a ciertos valores dados h_i para $i = 1, 2, \dots, p$, donde $n(x) = h_i$. En el ámbito de las redes neuronales artificiales los puntos $n(x) = h_i$ forman hiperplanos en X , conocidos como funciones discriminantes. De este modo, si en $X = x$ se tiene que x pertenecerá a cierta clase si $n(x) \geq h_i$. Esto es el principio de operación de la Perceptrón, creada por Rosenblatt 1958 y su éxito inicial se debió a que era capaz de aprender y reconocer patrones sencillos (Rosenblat, 1962).

Para una red neuronal artificial, X constituye “la señal de entrada”; Bishop (2008) describe a la función discriminante como una combinación lineal de las señales de entrada a la red neuronal artificial, en la cual los coeficientes son los parámetros del modelo obtenido que representa a la combinación lineal. La función discriminante para el problema de clasificación se muestra en la ecuación 1, donde W, x y b en notación matricial son denominados matriz de pesos, vector entradas y bias (o umbral), respectivamente.

$$n(x) = W^*x + b \quad (1)$$

La función discriminante es una recta (en el caso del plano) cuya posición está determinada por los coeficientes de la ecuación 1 al hacer $n(x) = 0$. Los valores contenidos en W y el valor b definen a la orientación y posición de la recta en términos de la distancia perpendicular de ésta a partir del origen. Para mayor información sobre la interpretación geométrica de la ecuación 1 véase Bishop (2008). Otro elemento importante en la aplicación de la Perceptrón en problemas de clasificación es la *función de transferencia* (ecuación 2).

$$a[n(x)] = f[n(x)] = f(W^*x + b) \quad (2)$$

Esta función de transferencia asocia a un valor $n(x)$ con su correspondiente *transformación* en la escala de $a[n(x)]$. Existen diferentes tipos de funciones de transferencia y su selección depende del tipo de red usada para los fines perseguidos. En esta investigación se empleo la función denominada *limitante duro* (hardlim), la cual tiene para $a[n(x)]$ sólo dos valores posibles, asignados como se indica en la ecuación 3.

$$a[n(x)] = \begin{cases} 1, & \text{cuando } n(x) \geq 0 \\ 0, & \text{cuando } n(x) < 0 \end{cases} \quad (3)$$

La salida de la unidad de procesamiento, $n(x)$, es la entrada a la función de *activación* que arrojará uno de dos valores posibles al usar (3); la salida será 1 si existe activación en la neurona y 0 en caso contrario. Para que haya activación será necesario que el producto de la señal de entrada con la magnitud de las conexiones sea mayor (o al menos igual) al inverso aditivo del umbral, o bien, $W^*x \geq -b$.

Cierta cantidad de vectores de entrada serán necesarios para entrenar a la Perceptrón. Así, un valor en X que haga verdadera a la inequación $n(x) \geq 0$ deberá ser asociado a $a[n(x)] = 1$, mientras que en caso contrario se tendrá $a[n(x)] = 0$. Esto ocurrirá para todos los valores en X que así deba ser, si se tienen los valores de W y b adecuados, obtenidos por el proceso de entrenamiento que minimice el error de falsas clasificaciones.

Clases en el gráfico de control de mediciones individuales

Como es conocido en el uso de los gráficos de control, cuando la variable aleatoria supervisada se comporta conforme a una distribución normal, los límites de control se encuentran comúnmente a una distancia de tres desviaciones estándar ($\pm 3\sigma$) de la línea central del gráfico. También se sabe que existen

diversas reglas universales como las General Electric que brindan pautas para detectar un comportamiento especial y a veces anormal en los datos, lo que indica que el proceso no se encuentra en control estadístico. Una de estas reglas señala que la detección de al menos un valor en X fuera del intervalo formado por los límites de control inferior y superior puede ser una señal de que el proceso sea considerado como fuera de control estadístico (Western Electric, 1956).

Un gráfico de control de mediciones individuales, tal como se muestra en la figura 1, tiene el eje horizontal que indica el tiempo y el vertical representa el espacio muestral de la variable aleatoria X . En este gráfico se aprecian tres rectas horizontales paralelas, que son el límite inferior de control (LIC), línea central (LC) y límite superior de control (LSC), que son calculados por el método convencional del gráfico de control de medias (Montgomery, 2009).

Considerando un proceso de producción donde sea de interés mantener bajo supervisión a X , de tal forma que se verifica $X \sim N(\mu, \sigma^2)$ y estableciendo para ello un gráfico de control de mediciones individuales, una vez calculados los límites superior e inferior de control, se pueden definir dos clases ($k = 1, 2$), tal como se ilustra en la figura 1.




Figura 1: Gráfico de control de rectas y discriminantes

De la figura 1 se advierte que, si $x = X$ entonces diferentes valores en X deberán ser clasificadas por su naturaleza numérica en dos clases:

- a. Clase 1 ($k = 1$): Cualquier x ubicada en $\{x \in X / LIC \leq x < LSC\}$
- b. Clase 2 ($k = 2$): Cualquier x ubicada en $\{x \in X / (x \leq LIC) \cup (x \geq LSC)\}$

Considerando lo anterior, la acción de ubicar cada x en las clases mencionadas define un problema de clasificación en el gráfico de control, si para toda $x = X$ se demuestra verdadera la ecuación 3.

Topología de la Perceptrón

La figura 2 muestra la topología de la Perceptrón con dos capas y 3 neuronas (dos en la primera capa y 1 en la segunda). Los superíndices de los escalares w, n, b y a refieren la capa de la red. Los subíndices de las w indican el número de la neurona.

Primera capa

Teniendo $W^{(1)} = [w_1^{(1)} w_2^{(1)}]^T$ y $b^{(1)} = [b_1^{(1)} b_2^{(1)}]^T$, al emplear la ecuación 1, se obtiene $n(x)^{(1)} = [w_1^{(1)} w_2^{(1)}]^T x + [b_1^{(1)} b_2^{(1)}]^T$, de donde se generan las ecuaciones no matriciales siguientes para la primera capa de la red de la figura 2:

$$n_1^{(1)}(x) = w_1^{(1)} x + b_1^{(1)} \tag{4}$$

$$n_2^{(1)}(x) = w_2^{(1)} x + b_2^{(1)}. \tag{5}$$




Figura 2: Representación gráfica de una red neuronal Perceptrón

Al emplear (2) y (3) se tienen las ecuaciones de las funciones de transferencia (valores del vector a) como sigue:

$$f[n_1^{(1)}(x)] = \text{hardlim}[n_1^{(1)}(x)] = a_1^{(1)}[n_1^{(1)}(x)] \quad (6)$$

$$f[n_2^{(1)}(x)] = \text{hardlim}[n_2^{(1)}(x)] = a_2^{(1)}[n_2^{(1)}(x)] \quad (7)$$

La salida de la capa 1 será un vector columna con dos elementos, esto es, $a^{(1)} = [a_1^{(1)} a_2^{(1)}]^T$ y es a su vez la señal de entrada a la segunda capa.

Segunda capa

En esta capa $w^{(2)} = [w_1^{(2)}, w_2^{(2)}]$ es la matriz de pesos que conecta a $a^{(1)}$ con la neurona. En la segunda capa la entrada es $a^{(1)}$ y no x , por lo que se tienen las ecuaciones no matriciales 8 y 9, respectivamente al usar (1) y (2).

$$w_1^{(2)} a_1^{(1)} + w_2^{(2)} a_2^{(1)} + b_1^{(2)} = n_1^{(2)}(a^{(1)}) \quad (8)$$

$$f[n_1^{(2)}(a^{(1)})] = \text{hardlim}[n_1^{(2)}(a^{(1)})] = a_1^{(2)} \quad (9)$$

El objetivo de la segunda capa es transformar a la salida de la capa 1 de un vector columna de dos elementos a un escalar, representado por $a_1^{(2)}$. En consecuencia, las dos capas de la figura 2 actúan entre sí para generar tal salida. La salida de la capa 1 tiene representación gráfica, tal como se ilustra en la figura 3. Tal salida, como se indicó, es la entrada a la segunda capa y la representación gráfica con una función discriminante cualquiera se muestra en la figura 4.

La figura 3 muestra a los límites de control como las rectas discriminantes formadas por la Perceptrón y las clases que creadas en la primera capa de la red. En la figura 4 se ilustra la segunda capa donde se generará el vector $a^{(2)}$, con elementos 0 y 1 de acuerdo a la aplicación de la función de transferencia hardlim . En la figura 4 se tiene la función discriminante $n_1^{(2)}[a^{(1)}] = 0$ a partir de la cual, si $f[n_1^{(2)}(a^{(1)})] \geq 0$ entonces $a_1^{(2)} = 1$. Para $X = x$, $a^{(1)} = [a_1^{(1)} a_2^{(1)}]^T = [1 \ 0]^T$ si x pertenece a la clase 1; de otro modo, para $a^{(1)} = [a_1^{(1)} a_2^{(1)}]^T = [1 \ 1]^T$ o $a^{(1)} = [a_1^{(1)} a_2^{(1)}]^T = [0 \ 0]^T$, entonces x será asignada a la segunda clase.

En la figura 4 se muestran 4 combinaciones gráficamente posibles para $a^{(1)}$, que son (i), (ii), (iii) y (iv), de las cuales sólo las tres últimas son factibles. El punto (i) es infactible dado que nunca habrá una salida de la primera capa de la red con los valores $[0 \ 1]^T$, dado que esto significa que una medición que esté por debajo del LIC y por arriba del LSC al mismo tiempo.




Figura 3: Salida de la capa 1a de la red




Figura 4: Entrada a la capa 2a

Método geométrico de entrenamiento de la Perceptrón

Para establecer el funcionamiento de la red Perceptrón para el gráfico de control de mediciones individuales, para una variable aleatoria $X \sim N(0, 1)$ como la señal de entrada a la primera capa, y donde $LSC = 3$ y $LIC = -3$, se deben obtener los valores de la matriz W y del vector b correspondientes a la primera y segunda capa; para este caso se obtendrá un peso w por cada límite de control así como un elemento b correspondiente, para lo cual se establece una ecuación para cada límite de control de la gráfica a partir del valor de la media de X denotado por \bar{x} en las ecuaciones 10 y 11.

$$\bar{x} - LIC = 0 \quad (10)$$

$$\bar{x} - LSC = 0 \quad (11)$$

Las ecuaciones 10 y 11 son entonces comparadas con la ecuación 1, de tal forma que por analogía de coeficientes de términos semejantes se tiene que si en (1) $n(x) = 0$, $W = [w_1^{(1)} w_2^{(1)}]^T = [1 \ 1]^T$ y $b = [b_1^{(1)} b_2^{(1)}]^T = [-LIC - LSC]^T = [3 \ -3]^T$. Finalmente se obtiene la ecuación 12.

$$\begin{bmatrix} n_1^{(1)}(x) \\ n_2^{(1)}(x) \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \end{bmatrix} x + \begin{bmatrix} 3 \\ -3 \end{bmatrix} \quad (12)$$

Aplicando las ecuaciones (6) y (7) en (12) se produce $a^{(1)} = [a_1^{(1)} a_2^{(1)}]^T$. Con este vector de salida de la capa 1 de la Perceptrón se tiene la entrada a la segunda capa. Se genera un plano respecto a las salidas $a_1^{(1)}$ y $a_2^{(1)}$ para luego establecer por inspección una función discriminante la cual lo atraviese de modo que el punto en el cual se ubican los valores que se encuentran dentro de los límites de control, se ubiquen separados por dicho límite de decisión de los demás valores que se encuentren no conformes (figura 5). La función discriminante establecida arrojará los valores correspondientes a los pesos y al bias para esta segunda capa de la red. En la figura 5 se observa que los puntos $(0, -1)$ y $(1, 0,7)$, definidos por inspección visual, pasan por la recta $n_1^{(2)}[a^{(2)}] = 0$, por lo que realizando los cálculos correspondientes se obtiene que la ecuación de la función discriminante está dada por:

$$1,7a_1^{(1)} - a_2^{(1)} - 1 = 0 \quad (13)$$

Al comparar (13) con (8) se obtienen los pesos de $W^{(2)}$ y el bias b , los cuales son $W^{(2)} = [w_1^{(2)}, w_2^{(2)}] = [1,7 \ -1]$ y $b = [-1]$. Finalmente, la salida de la segunda capa de la Perceptrón es:

$$a^{(2)} = \text{hardlim}(n_1^{(2)}) = \text{hardlim}(1,7a_1^{(1)} - a_2^{(1)} - 1) \quad (14)$$

El proceso mostrado en esta sección corresponde al entrenamiento de la red y difiere de los métodos basados en mínimos cuadrados. La forma de entrenamiento empleada en esta investigación está acorde




Figura 5: Representación gráfica de las salidas de la primera capa de la Perceptrón

con el teorema de convergencia de la Perceptrón; aborda las propiedades geométricas de la Perceptrón que permiten equiparar las rectas discriminantes de la red con los gráficos de control, para clasificar a los puntos medidos en dos estados de forma lineal.

Para un vector de m mediciones individuales de X , de media cero y varianza 1, llamado x y de dimensiones $1 \times m$, el código en MATLAB, que clasifica a cada uno de sus elementos, conforme a la ecuación 14 y produce la salida a_2 , es

```
% primera capa
w1=[1;1]; pr1=[1,1]; s1=2;
net1=newp(pr1,s1);
net1.iw{1,1}=w1;
net1.b{1}=[3;-3];
a1 = sim(net1,x);
% segunda capa
w2=[1.7,-1]; pr2=[2,2;2,2]; s2=1;
net2=newp(pr2,s2);
net2.iw{1,1}=w2;
net2.b{1}=-1;
a2 = sim(net2,a1)
```

Pruebas y resultados

Por simulación se generaron en MATLAB distintos vectores de datos de una variable aleatoria empleando el comando $X = normrnd(a,b,c,d)$ conforme a lo indicado en el cuadro 1, donde a y b son la media y desviación estándar de los valores generados, y c y d las dimensiones del vector creado. Se expresa que cuando $a = 0$, los datos generados serán no contaminados. Para esta investigación, b, c y d fueron constantes en los valores 1, 1 y 60 respectivamente, mientras que para a se consideraron distintos casos que representan “cambios en el nivel de la media del proceso” (o contaminación de los datos) en ciertas cantidades, que fueron 5 %, 15 %, 25 % y 35 % sobre el vector cx_d . Estos porcentajes de contaminación se

	Porcentaje de contaminación											
	5 %			15 %			25 %			35 %		
Cambio en la media	P	GC	Dif.	P	GC	Dif.	P	GC	Dif.	P	GC	Dif.
0.5	6	12	-6	18	16	+2	2	4	-2	6	8	-2
1.0	12	11	+1	14	8	+6	16	4	+12	24	4	+20
1.5	22	16	+6	34	10	+24	50	10	+40			
2.0	10	14	-4	72	2	+70						
2.5	25	24	+1									
3	80	34	+46									

Cuadro 1: Puntos clasificados en $k = 2$ por la Perceptrón y puntos fuera de control detectados por gráfico de control.

aplicaron para cada valor de a , donde $a = 0,5, 1,0, 1,5, 2,0, 2,5$ y $3,0$, como se muestra en el cuadro 1 y fueron colocados aleatoriamente dentro del vector de datos.

La estadística empleada para evaluar el desempeño de la aplicación de la Perceptrón en comparación con el uso del gráfico de control de mediciones individuales fue el número de muestras unitarias clasificadas en la clase $2(k = 2)$, por la salida de la red igual a 0 comparado con la cantidad de puntos fuera de control detectados por el gráfico de mediciones individuales en 50 simulaciones.

El cuadro 1 muestra los resultados obtenidos. En este cuadro se observan celdas vacías en algunas combinaciones del porcentaje de contaminación de los datos y nivel de cambio en la media, lo cual se debió a que en tales combinaciones la prueba de hipótesis del valor de la media de los datos, para variables aleatorias con varianza conocida, bajo las hipótesis:

H_0 : la media del proceso es cero

H_1 : la media del proceso es mayor a cero

resultó en el rechazo de la hipótesis nula en más del 10 % de las veces y ello implica que la media de los datos ha cambiado y por tanto la contaminación es ya severa y es fácilmente detectable por cualquier medio estadístico y la Perceptrón no produce mejores resultados.

La diferencia (Dif. en el cuadro 1) se calcula como “puntos clasificados” en $k = 2$ por la Perceptrón menos puntos fuera de límites de control. Esta medida de eficiencia comparativa señala la ventaja del uso de la Perceptrón sobre el gráfico de control de mediciones individuales. La figura 6 muestra la gráfica de la medida Dif. del cuadro 1. Se observa lo siguiente: A medida que aumenta el nivel de contaminación en los datos y la magnitud del cambio del valor de la media, se obtiene mejor potencial de clasificación de puntos fuera de control por la Perceptrón que por el gráfico de control de mediciones individuales. Esta diferencia favorece al desempeño de la Perceptrón en los niveles de contaminación de los datos de 15 %, 25 % y 35 %. Esta diferencia se observa nula para el nivel de contaminación del 5 % de los datos, salvo cuando el cambio en la media es de 3 unidades.

Conclusiones

En esta investigación se demuestra que el uso de la Perceptrón sobre el Gráfico de Control de mediciones individuales es deseable, dado que identifica mayor cantidad de puntos indicativos de causas especiales de variación en el proceso. Por otra parte, se demostró que el gráfico de control de mediciones individuales funciona igual que la Perceptrón en bajos niveles de contaminación de datos, o bien, en desviaciones pequeñas de la media (menores a una desviación estándar), lo que constituyó la segunda aportación de esta investigación. Finalmente, con el método de entrenamiento de la red propuesto, basado en las propiedades geométricas de la red, se posibilita un entrenamiento rápido, eficiente y sencillo, lo cual ayuda a la puesta en funcionamiento en líneas de producción donde métodos de fácil entendimiento




Figura 6: Diferencia entre puntos fuera de control localizados por la Perceptrón sobre el gráfico de control

deben ser empleados; esta característica no se tiene con otras redes neuronales artificiales que son de estructura más compleja que la Perceptrón, tanto en su topología como en el proceso de entrenamiento, sin embargo, otras redes pueden ser usadas para reconocer otros patrones especiales de variación en otros tipos de gráficos de control.

Referencias

- [1] Bishop, C. M. (2008). *Neural Network for Pattern Recognition*. New York: Oxford University Press.
- [2] Duda, R. O., Hart, P. E. & Stock, D. G. (2001). *Pattern Classification*. United States of America: John Wiley & Sons.
- [3] 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.
- [4] Gutiérrez-Rosas P.T., Vázquez-López J.A., Hernández Ripalda M.D., Hernández-González S., López-Juárez I. (2012). Uso de la red neuronal Perceptrón para detección de cambios pequeños en la media en los gráficos de control. *1st LACCEI International Symposium on Software Architecture and Patterns (LACCEI-ISAP-MiniPLOP2012)*, July 23-27, 2012, Panama City, Panama.
- [5] Montgomery, D. C. (2009). "Statistical Quality Control". United States of America: John Wiley & Sons, Inc.
- [6] 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.

- [7] Rosenblatt, F. (1962). Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms. Spartan.
- [8] Theodoridis, S. & Koutroumbas, K. (2009). Pattern Recognition. Canada: Academic Press. The Mathworks Inc. (2009). MATLAB. Natick, MA.
- [9] 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.
- [10] Western Electric. (1956). Statistical Quality Control Handbook. Indianapolis, IN.: AT& T.
- [11] Vázquez-López, J. A., López-Juárez, I., Peña-Cabrera, M. (2010). On the Use of the FuzzyARTMAP Neural Network for Pattern Recognition in Statistical Process Control using a Factorial Design. International Journal of Computers, Communications & Control, V, (2), 205-215.
- [12] Zobel, C.W., & Cook, D.F.Q. (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.