

Reconocimiento de patrones en gráficos de control utilizando una red neuronal

GUARNEROS-RIVERA, Manuel*†, DÍAZ, LÓPEZ-CHAU, Asdrúbal, MUÑOZ-CONTRERAS, Hilarion y PELÁEZ-CAMARENA, Silvestre Gustavo

Instituto Tecnológico de Orizaba, Oriente 9, Emiliano Zapata Sur, C.P. 94320 Orizaba, Veracruz, México

Recibido Julio 5, 2017; Aceptado Septiembre 15, 2017

Resumen

Los gráficos de control son una herramienta importante en el control de procesos estadístico para mejorar la calidad de los productos mediante estabilidad y reducción de la variabilidad. Los patrones no naturales en los gráficos de control suponen que existe una causa asignable que afecta al proceso y que se deben tomar acciones para solucionar el problema. Debido a su capacidad y rapidez de reconocimiento, las redes neuronales proporcionan gran rendimiento para reconocer tendencias en los procesos. En este artículo, se describe un modelo de red neuronal para el reconocimiento de patrones en gráficos de control. Los resultados señalan una configuración de red que lleva a una buena calidad de reconocimiento.

Perceptron multicapa, Retropropagación, Reconocimiento de patrones de gráficos de control

Abstract

Control charts are an important tool in statistical process control to improve product quality through stability and variability reduction. Unnatural patterns in control charts assume that there is an assignable cause that affects the process and that actions must be taken to solve the problem. Because of their ability and speed of recognition, neural networks provide great performance to recognize process trends. In this paper, we describe a neural network model for pattern recognition in control charts. The results indicate a network configuration leading to good recognition quality.

Backpropagation, control chart pattern recognition, multilayered perceptron

Citación: GUARNEROS-RIVERA, Manuel, DÍAZ, LÓPEZ-CHAU, Asdrúbal, MUÑOZ-CONTRERAS, Hilarion y PELÁEZ-CAMARENA, Silvestre Gustavo. Reconocimiento de patrones en gráficos de control utilizando una red neuronal. Revista de Tecnología Informática 2017, 1-2: 1-8

* Correspondencia al Autor (Correo Electrónico: mrivera@acm.org)

† Investigador contribuyendo como primer autor.

Introducción

El Control estadístico de Procesos (CEP), es un concepto que está ligado con la calidad, es una herramienta que muestra el estado de un proceso de transformación en términos estadísticos, lo cual permite monitorear y establecer parámetros para su mejor control, además es útil para conseguir estabilidad y mejorar la capacidad del proceso mediante la reducción de variabilidad [1]. Los gráficos de control son elaborados a partir de los valores medidos de muestras tomadas del proceso, los gráficos son una herramienta que se utiliza para analizar datos estadísticos de manera sofisticada, muestran la cantidad y la naturaleza de la variación de un proceso, indican el control estadístico o la falta de él y permiten la interpretación y detección de patrones de cambio en el proceso de estudio [2]. El reconocimiento exacto y rápido de los patrones de cambio en gráficos de control es esencial para mantener productos de alta calidad.

Varios enfoques se han propuesto para el reconocimiento de patrones en gráficos de control, incluidos sistemas basados en reglas [3], sistemas expertos [4] y con redes neuronales artificiales [5-19]. La ventaja de un sistema experto o basado en reglas es que contiene la información explícitamente, si es necesario, las reglas pueden ser modificadas y actualizadas fácilmente, sin embargo, el uso de las reglas basadas en propiedades estadísticas tiene la dificultad de que pueden derivar en propiedades estadísticas similares para algunos patrones de diferentes clases, lo que puede crear problemas de reconocimiento incorrecto.

Las redes neuronales artificiales han sido ampliamente aplicadas en el reconocimiento de patrones.

Estas redes han demostrado ser buenas alternativas a los sistemas tradicionales de reconocimiento de patrones en gráficos de control, debido a sus características para generalizar, su facilidad de implementación y la capacidad de manejar medidas ruidosas que no requieren ninguna suposición acerca de la distribución estadística de los datos monitorizados.

La mayoría de los investigadores han utilizado redes neuronales artificiales supervisadas, tales como perceptrón multicapa (MLP), función de base radial (RBF) [20] y cuantificación del vector de aprendizaje (LVQ) [21] para clasificar diferentes tipos de patrones en gráficos de control. El perceptrón multicapa, con algoritmo de aprendizaje de retro propagación, es quizás el modelo de red neuronal más utilizado, siendo fácil de entender y de implementar. Algunos otros investigadores han utilizado fuzzy clustering [22] para el reconocimiento de patrones. Un clasificador basado en árbol de decisiones (DT) [23] también es popular para el problema del reconocimiento de patrones en gráficos de control. Para el aprendizaje de redes neuronales, es necesario encontrar un algoritmo que aprenda bien y rápidamente. Hay algunas comparaciones disponibles en la literatura, pero no dan un concepto preciso para determinar si un algoritmo es mejor para una aplicación específica.

Este artículo describe una red neuronal artificial multicapa para identificar situaciones fuera de control en gráficos de control con el fin de mejorar la capacidad de detección de patrones. La red esta entrenada para diferentes estructuras y se han evaluado varias reglas de aprendizaje usadas para ajustar los pesos de la red neuronal. Se conserva la mejor configuración y el algoritmo más preciso.

En resto del artículo está organizado en 5 secciones. En la Sección 2, se presenta una breve revisión del perceptrón multicapa MLP y el algoritmo para su entrenamiento. En la Sección 3 se muestra la aplicación de MLP al problema de reconocimiento de patrones en gráficos de control. Los resultados obtenidos con datos obtenidos de la replicación de registros de una empresa alimentaria se presentan en la Sección 4. En la Sección 5 se encuentran las conclusiones de este trabajo. Las referencias utilizadas están al final del presente artículo.

Perceptrón Multicapa (MLP)

Como se muestra en la Figura 1, MLP consta de tres tipos de capas: una capa de entrada, una capa de salida y una o más capas ocultas. Las neuronas en la capa de entrada actúan solamente como reguladores para distribuir la señal de entrada x_i a las neuronas en la capa oculta. Cada neurona j en la capa oculta añade sus señales de entrada x_i después de multiplicarlas por las resistencias de los respectivos pesos de conexión w_{ji} y calcula su salida y_j como una función de la suma, es decir;

$$y_j = f \sum (w_{ji} x_i) \quad (1)$$

f es generalmente una función tangente sigmoïdal o hiperbólica. Las salidas de las neuronas en la capa de salida se calculan de manera similar.

El entrenamiento de una red consiste en ajustar sus pesos usando un algoritmo de entrenamiento. El algoritmo de entrenamiento adoptado en este estudio optimiza los pesos intentando minimizar la suma de las diferencias cuadradas entre los valores deseados y reales de las neuronas de salida, es decir;

$$E = \frac{1}{2} \sum_j (y_{dj} - y_j)^2 \quad (2)$$

Donde y_{dj} es el valor deseado de la neurona de salida j y y_j es la salida real de esa neurona.

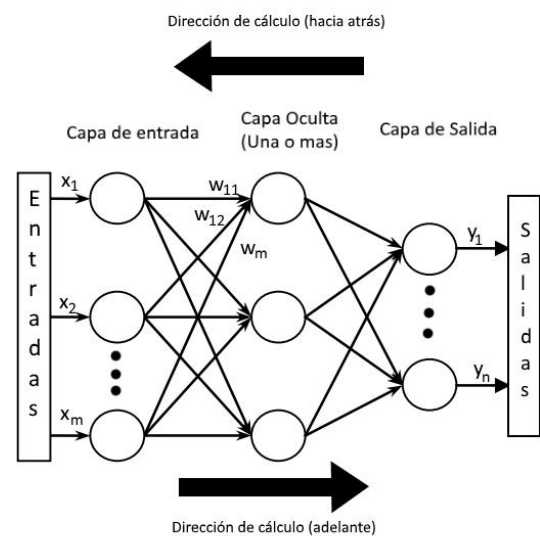


Figura 1 Estructura básica de un perceptrón multicapa

Cada peso w_{ji} se ajusta añadiendo un incremento Δw_{ji} a él. w_{ji} se selecciona para reducir E tan rápidamente como sea posible. El ajuste se realiza a lo largo de varias iteraciones de entrenamiento hasta que se obtiene un valor satisfactorio pequeño de E o se alcanza un número dado de iteraciones. La forma en que w_{ji} se calcula depende del algoritmo de entrenamiento adoptado. El algoritmo adoptado en este trabajo se describe brevemente a continuación.

Algoritmo de Retropropagación "Backpropagation" (BP)

El algoritmo de retropropagación (BP) da el cambio $\Delta w_{ji}(k)$ en el peso de la conexión entre las neuronas i y j en la iteración k como

$$\Delta w_{ji}(k) = -\alpha \frac{\delta E}{\delta w_{ji}(k)} + \mu \Delta w_{ji}(k-1) \quad (3)$$

Donde α corresponde al coeficiente de aprendizaje, μ el coeficiente de momento y $\Delta w_{ji}(k-1)$ el cambio de peso en la iteración inmediata anterior.

El entrenamiento de un MLP por BP implica presentarlo secuencialmente con todas las tuplas de entrenamiento. Las diferencias entre la salida objetivo $y_d(k)$ y la salida real $y(k)$ del MLP se propagan de nuevo a través de la red para adaptar sus pesos. Una iteración de entrenamiento se completa después de que una tupla en el conjunto de entrenamiento ha sido presentada a la red y los pesos actualizados.

Reconocimiento de Patrones en gráficos de control

En este trabajo, se usa un MLP para reconocimiento de patrones en gráficos de control. Los gráficos de control se utilizan para supervisar el comportamiento de un proceso. La Figura 2 muestra los 6 tipos principales de patrones que se pueden observar en un gráfico de control: normal (NR), cíclico (CC), desplazamiento hacia abajo (DS), desplazamiento hacia arriba (US), tendencia creciente (UT) y tendencia decreciente (DT). Todos los patrones, excepto el patrón normal, indican que el proceso que se está monitoreando no está funcionando correctamente y requiere ajuste.

Para este trabajo, los patrones de los seis diferentes tipos fueron generados replicando datos registrados de una empresa alimentaria, obtenidos en un estudio para ver el estado de control de sus procesos. Cada patrón se tomó como una serie de tiempo de 24 datos. Cuatrocientos veinte patrones, 70 de cada tipo se generaron en total. Doscientos cuarenta patrones se utilizaron para la formación del clasificador perceptrón multicapa y el resto para la prueba del clasificador entrenado.




Figura 2 Patrones básicos en gráficos de control: (a) Patrón normal, (b) Patrón Cíclico, (c) Tendencia decreciente, (d) Tendencia creciente, (e) Desplazamiento hacia abajo, (f) Desplazamiento hacia arriba

Antes de que los datos fueran presentados a la red, se implementaron dos etapas de preprocesamiento de datos: normalización y codificación. La normalización es un proceso de transformación lineal: a través del cual la variable de datos brutos X se transforma en una nueva variable Z , es decir;

$$z(t) = (x(t) - \mu) / \sigma \quad (4)$$

La variable $z(t)$ seguirá una distribución normal estándar con una media cero y una desviación estándar de la unidad siempre que $x(t)$ siga una distribución normal.

El proceso de normalización reduce los datos a un rango constante, aproximadamente $[-3, +3]$, independientemente de los valores que tomaron los datos antes de la normalización. Esta transformación es necesaria porque una red neuronal entrenada sólo puede aceptar un cierto rango de datos de entrada.

Un proceso de codificación se implementó después de la normalización para reducir el efecto del ruido en los datos de entrada antes de que los datos fueran presentados a la red. El esquema de codificación funciona como una operación de suavizado para filtrar las pequeñas variaciones aleatorias mientras se conservan las características principales de los datos. Esta codificación permitió que la convergencia se produjera más fácilmente.

Cada red tenía 24 neuronas de entrada, una para cada dato en la serie temporal y 6 neuronas de salida, una para cada tipo de patrón de gráfico de control. La tabla 1 representa los patrones de gráficos de control y la representación de las salidas de la red neuronal deseadas.

La estructura del clasificador propuesto se muestra en la Figura 3. Se observa que este sistema se compone de una capa oculta de tres neuronas. El número de capas ocultas fue elegido ya que se había encontrado adecuado para la mayoría de los problemas de clasificación.

El clasificador fue entrenado utilizando el algoritmo BP. Los valores de los parámetros de entrenamiento adoptados para los algoritmos se determinaron empíricamente. Fueron los siguientes: para BP $\alpha = 0.9$ y $\mu = 0.5$.

Clase	Descripción	Salida de la Red neuronal					
1	Tendencia creciente (UT)	1	0	0	0	0	0
2	Tendencia decreciente (DT)	0	1	0	0	0	0
3	Normal (NR)	0	0	1	0	0	0
4	Cíclico (CC)	0	0	0	1	0	0
5	Desplazamiento hacia arriba (US)	0	0	0	0	1	0
6	Desplazamiento hacia abajo (DS)	0	0	0	0	0	1

Tabla 1 Patrones de gráficos de control y representación de las salidas deseadas de la red neuronal

Se registró el número de iteraciones de entrenamiento requeridas para lograr el valor de E . El criterio de parada real empleado fue la suma de los cuadrados del error, que se define como:

$$SSE = \sum_{i=1}^M \sum_{j=1}^N (y_{dj}^{(i)} - y_j^{(i)})^2 \tag{5}$$

Donde N es el número de salidas y M es el número de patrones en el conjunto de entrenamiento. El clasificador fue entrenado hasta que se definió el número de iteraciones fijado en 1000.




Figura 3 Estructura del clasificador propuesto

Resultados

Para el estudio, se utilizó el 60% de los datos para la formación del clasificador y el resto para la prueba. La manera típica de evaluar la tasa de rendimiento es elegir un conjunto de pruebas independiente del conjunto de entrenamiento para clasificar sus elementos, contar los elementos que se han clasificado correctamente y dividir por el tamaño del conjunto de pruebas.

La proporción de elementos del conjunto de pruebas que clasifican correctamente del total de elementos estima el rendimiento del clasificador para cada patrón. Los resultados preliminares se pueden apreciar en la Tabla 2, como puede observarse el clasificador reconoce los seis tipos de patrones con una media de precisión de 94.445%.

Clase	Descripción	Precisión de clasificación (%)
1	Tendencia creciente (UT)	96.67
2	Tendencia decreciente (DT)	93.33
3	Normal (NR)	96.67
4	Cíclico (CC)	90.00
5	Desplazamiento hacia arriba (US)	93.33
6	Desplazamiento hacia abajo (DS)	96.67

Tabla 2 Precisión de Reconocimiento del clasificador

Los valores en la matriz diagonal de confusión muestran el desempeño correcto del clasificador para cada patrón. Estos valores muestran que varios de los patrones considerados son reconocidos correctamente. Por ejemplo, en la primera fila de la matriz, en la Tabla 3, el valor 96.67% muestra el porcentaje de reconocimiento correcto del patrón de tendencia creciente y el valor 3.33% muestra que este tipo de patrón se reconoce erróneamente con el patrón de desplazamiento hacia arriba.

	UT	DT	NR	CC	US	DS
UT	96.67	0	0	0	3.33	0
DT	0	93.33	0	0	0	6.67
NR	0	0	96.67	3.33	0	0
CC	3.33	3.33	3.33	90.0	0	0
US	6.67	0	0	0	93.33	0
DS		3.33				96.67

Tabla 3 Matriz de confusión del clasificador (%)

Conclusiones

Los gráficos de control son importantes herramientas estadísticas de control de procesos para determinar si un proceso se ejecuta en su modo deseado o existe presencia de patrones no naturales al proceso. Este estudio abordó el diseño de un clasificador para el reconocimiento de patrones en gráficos de control. Se propone un clasificador MLP (perceptrón multicapa) que se compone de una capa oculta con tres neuronas, entrenado con el algoritmo de retropropagación para el reconocimiento de los seis patrones básicos en gráficos de control. La complejidad de este clasificador propuesto es menor a otras obras no obstante la precisión más alta obtenida de manera preliminar es de 96.67%.

Con el fin de aumentar la precisión de clasificación se plantea una optimización de la estructura de la red neuronal, la integración con otras técnicas que permitan un mejor razonamiento de la red neuronal en la etapa del entrenamiento así como una mejor clasificación de los elementos a clasificar. Es posible combinar el modelo propuesto con otras redes neuronales o sistemas expertos para inferir las causas relevantes de las variaciones y facilitar el control automático de la calidad.

Referencias

Montgomery, D. (2001). Introduction to statistical quality control., 5th edition, John Wiley, Hoboken.

Amitava, M. (2006). Fundamentals of Quality Control and Improvement, 2nd edition, Thompson.

Ataollah, E. y Vahid, R. (2009). A hybrid intelligent technique for recognition of control chart patterns, 2009 First International Conference on Networked Digital Technologies, Ostrava, pp. 32-36.

Jenn, H.Y. y Miin-Shen, Y. (2005). A control chart pattern recognition system using a statistical correlation coefficient method, *Computers & Industrial Engineering*, vol. 48, pp 205-221.

Cheng, C. (1997). A neural network approach for the analysis of control chart patterns, *International Journal of Production Research*, vol. 35, pp. 667-697.

Ruey-Shy, G. y Yi-Chih, H. (1999). A neural network based model for abnormal pattern recognition of control charts, *Computers & Industrial Engineering*, vol. 36, pp. 97-108.

Jianbo, Y. y Lifeng, X. y Bin, W. (2007). A Neural Network Ensemble Approach for the Recognition of SPC Chart Patterns, *Third International Conference on Natural Computation (ICNC 2007)*, pp. 575-579.

Zhiqiang, C. y YiZhong, M. (2008). A Research about Pattern Recognition of Control Chart Using Probability Neural Network, *2008 ISECS International Colloquium on Computing, Communication, Control, and Management*, pp. 140-145.

Mahmoud, B. (2015). An Effective and Novel Neural Network Ensemble for Shift Pattern Detection in Control Charts, *Computational Intelligence and Neuroscience*, vol. 2015.

Ataollah, E. y Vahid R. (2010). Control chart pattern recognition using an optimized neural network and efficient features, *ISA Transactions*, vol. 49, pp. 387-393.

Ruey-Shiang, G. (2004). Optimizing feedforward neural networks for control chart pattern recognition through genetic algorithms. *International Journal of Pattern Recognition and Artificial Intelligence*, vol. 18, p. 75-99.

Marcus, P. y Julie, K. y Tomas V. (2004). Control chart pattern recognition using back propagation artificial neural networks, *International Journal of Production Research*, vol. 39, pp. 3399-3418.

Ataollah, E. y Jalil A. y Zahra R. (2011). Control chart pattern recognition using K-MICA clustering and neural networks, *ISA Transactions*, vol. 51, pp. 111-119.

Lesany, S. y Koochakzadeh, A. y Fatemi G. (2014). Recognition and classification of single and concurrent unnatural patterns in control charts via neural networks and fitted line of samples, *International Journal of Production Research*, vol. 52, pp. 1771-1786.

Ruey-Shiang, G. (1999). Recognition of control chart concurrent patterns using a neural network approach, *International Journal of Production Research*, vol. 37, pp. 1743-1765.

Yousef, A. (2004). Recognition of control chart patterns using multiresolution wavelets analysis and neural networks, *Computers & Industrial Engineering*, vol. 47, pp. 17-29.

Bidyut B. (2009). Recognition of quality control chart patterns based on back propagation neural network, *2009 16th International Conference on Industrial Engineering and Engineering Management*, pp. 1124-1128.

Duc, P. y Seref, S. (2000). Training multilayered perceptrons for pattern recognition: a comparative study of four training algorithms, *International Journal of Machine Tools and Manufacture*, vol. 41, pp. 419-430.

Omar, E. y Ali, M. y Said, B. (2015). Using Artificial Neural Networks for Recognition of Control Chart Pattern, *International Journal of Computer Applications*, vol. 116.

Jalil, A. y Ata, E. y Milad, A. y Vahid, R. (2014). Statistical process control using optimized neural networks: A case study, *ISA Transactions*, vol. 53, pp. 1489-1499.

Ruey-Shiang, G. (2005). A hybrid learning based model for online detection and analysis of control chart patterns, *Computers & Industrial Engineering*, vol. 49, pp. 35-62.

Amir, B. y Abdolreza, G. y Masoud, A. y Jalil A. (2013). Control Chart Patterns Recognition Using Optimized Adaptive Neuro-Fuzzy Inference System and Wavelet Analysis, *Journal of Engineering and Technology*, vol. 3.

Chih-Hsuan, W. y Ruey-Shan, G. y Ming-Huang, C. y Jehn-Yih, W. (2007). Decision tree based control chart pattern recognition, *International Journal of Production Research*, vol.46, pp. 4889-4901.