



Industrial Data

ISSN: 1560-9146

iifi@unmsm.edu.pe

Universidad Nacional Mayor de San Marcos

Perú

Cevallos Ampuero, Juan

Aplicación de redes neuronales para optimizar problemas multirespuesta en mejora de la calidad

Industrial Data, vol. 7, núm. 2, julio-diciembre, 2004, pp. 31-34

Universidad Nacional Mayor de San Marcos

Lima, Perú

Disponible en: <http://www.redalyc.org/articulo.oa?id=81670205>

- ▶ Cómo citar el artículo
- ▶ Número completo
- ▶ Más información del artículo
- ▶ Página de la revista en redalyc.org

 redalyc.org

Sistema de Información Científica

Red de Revistas Científicas de América Latina, el Caribe, España y Portugal
Proyecto académico sin fines de lucro, desarrollado bajo la iniciativa de acceso abierto

APLICACIÓN DE REDES NEURONALES PARA OPTIMIZAR PROBLEMAS MULTIRESPUESTA EN MEJORA DE LA CALIDAD

Recepción: Noviembre de 2004 / Aceptación: Diciembre 2004

⁽¹⁾ Juan Cevallos Ampuero

RESUMEN

El artículo trata sobre la aplicación de redes neuronales en problemas multirespuesta para el mejoramiento de la calidad, a partir de un análisis conceptual se establece una aplicación que demuestra la eficacia de las redes neuronales utilizando la red backpropagation con entrenamiento, mediante el algoritmo backpropagation - traingdm.

Palabras Claves: Mejora de la calidad. Optimización. Multirespuesta. Redes neuronales.

APPLICATION OF NEURONAL NETWORKS TO ENHANCE MULTI-ANSWER PROBLEMS TO IMPROVE QUALITY

ABSTRACT

This article deals with the application of neuronal networks in multi-answer problems to improve quality. From a conceptual analysis, an application showing the efficiency of neuronal networks using the backpropagation network with training is shown through backpropagation-traingdn.

Key words: Quality improvement. Multi-answer. Neuronal network.

INTRODUCCIÓN

En la actualidad se considera que el éxito en la competencia por los mercados se logra en base a la calidad de los productos y servicios, para ello se trabaja en la mejora continua de la calidad. La mejora de la calidad se logra, de manera significativa, mediante la mejora de los diseños y procesos, para ello se trabaja con varias variables de entrada, en especial con los parámetros de proceso y se busca obtener un producto de mejor calidad analizando varias variables de resultado, o características de calidad. Es decir interesa conocer los resultados de varias variables que actúan de manera simultánea tanto en procesos como en productos terminados. Es lo que se conoce como el control de calidad dentro y fuera de la línea.

Para lograr un producto con características de calidad superiores al resto, se requiere realizar múltiples investigaciones con los diversos parámetros de los procesos, llegando a determinar los parámetros más importantes con una precisión cada vez mayor y, a la vez, lograr características de calidad que estén cada vez más cerca de los valores objetivos, todo ello con una menor variabilidad. Se requieren hacer estudios de los procesos y resultados que a la vez consideren muchas variables de manera simultánea, que es justamente lo que se puede realizar con el uso del diseño de experimentos y otras herramientas estadísticas. Sin embargo, este tipo de estudios ha dejado de ser exclusividad de la estadística y se vienen utilizando las redes neuronales para ello, con resultados bastante aceptables. Por un lado las técnicas estadísticas como el Análisis de Varianza ANOVA, que se usa en el diseño de experimentos, considera sólo las variables significativas; las Metodologías de Superficies de Respuestas consideran complicados cálculos estadísticos; las Funciones de Deseabilidad, desarrolladas por Derringer y Suich (1980) requieren el planteamiento de múltiples ecuaciones, el uso de software y ploteos, y por otro lado, las redes neuronales consideran todas las variables y su aplicación es más simple.

Entre los estudios sobre solución de problemas multirespuesta se encuentran los de Derringer y Suich que proponen un procedimiento para optimizar mediante el uso de la función de deseabilidad; Khuri y Conlon, desarrollaron un procedimiento, basado en modelos de regresión polinomial para optimizar la simulación de varias respuestas; Del Castillo et al. (1996), desarrollaron una función de deseabilidad modificada para optimizar respuestas múltiples; Tong y Su, aplicaron la lógica difusa para optimizar problemas de respuesta múltiple.

(1) Magíster en Ingeniería Industrial. Profesor del Departamento de Gestión y Producción Industrial, UNMSM. E-mail: jceval@terra.com.pe

>>> Aplicación de Redes Neuronales para Optimizar Problemas Multirespuesta en Mejora de la Calidad

REDES NEURONALES

Las Redes Neuronales Artificiales-RNA (que por lo general se denominan Redes Neuronales), se basan en la concepción sobre el funcionamiento del sistema nervioso humano y en la teoría general de redes a la solución de problemas.

Las Redes Neuronales Artificiales, tienen en su base lo que se conoce como la Neurona Artificial, la misma que se ha desarrollado aspirando que se asemeje al funcionamiento de una neurona biológica; así cada neurona artificial tiene entradas y salidas, pesos sinápticos, regla de propagación, función de activación y función de salida. Las neuronas individuales se agrupan según determinadas arquitecturas conformando capas y el conjunto de capas forma la red neuronal.

Se considera que una red neuronal tiene una capa de entrada y una capa de salida y dependiendo el uso que se quiera dar a la red neuronal, se tendrá una o más capas ocultas (intermedias). Cada capa de neuronas tiene su respectiva función de activación y de salida, que permite transformar una entrada en salida.


Las redes de neuronas artificiales emulando a las biológicas tienen un mecanismo de aprendizaje, que se basa fundamentalmente en el criterio de prueba y error. Es decir, se aplica una función para determinada entrada y si no se obtiene la salida buscada; se vuelve a probar la red pero variando los pesos sinápticos (tasa de variación); si nuevamente no se obtiene la salida esperada se vuelve a probar, previa variación de los pesos sinápticos, y así sucesivamente, hasta obtener la salida buscada.

Este paso de los datos para probar si la red permite obtener el resultado esperado se conoce como *epoch*; por lo general para resolver un problema, una red realiza más de 1 000 epochs (es decir cálculos); no siempre llega a una solución. Si no se llega a la solución con una red se deberá probar otro algoritmo de los que hay desarrollados (en la actualidad pasan de los 20).

Una vez que se ha logrado la salida buscada, termina la etapa de aprendizaje de la red y ahora se puede dar a la red una entrada cualquiera entonces la red opera y obtiene la salida respectiva según las funciones de la red entrenada. Es decir, se tienen dos etapas distintas: una, de entrenamiento de la red (búsqueda de la salida esperada) y la otra, de aplicación de la red entrenada a cualquier entrada y obteniendo la respectiva salida.

Según el tipo de arquitectura y funciones que se utilicen se tienen diversos modelos de redes neuronales artificiales. Los modelos más conocidos se clasifican en supervisados y no supervisados. Dentro de los primeros se tienen los modelos más simples y las que más se utilizan: Perceptrón, Backpropagation BP, Adalina, LVQ, GRNN, Perceptrón Multicapa, Madalina. Dentro de los no supervisados son usados el de Realimentación de Hopfield y el Unidireccional de Mapas de Kohonen.

En general, el modelo más utilizado en la actualidad es el de la Red Backpropagation, con diversos algoritmos de entrenamiento. La topología de la red neuronal *backpropagation* es la que se presenta en el siguiente diagrama:



PROBLEMAS MULTIRESPUESTA Y SOLUCIÓN ESTADÍSTICA

Para explicar que es un problema multirespuesta y la técnica estadística más exitosa a la fecha para su solución se utilizará el ejemplo del artículo "Modified Desirability Functions for Multiple response Optimization", publicado por Del Castillo, Montgomery y McCarville, del Journal of Quality Technology, Vol. 28, N° 3.

En este caso Del Castillo et al. (1996), presentan un ejemplo aplicativo sobre una faja transportadora metálica para calentamiento y adhesión de conductores de circuitos integrados en placas de plástico. El calentamiento se da en un proceso continuo a través de una corriente de aire caliente (X1), de la faja metálica a la temperatura (X2), y de un bloque de calentamiento a alta temperatura (X3). Se busca obtener la placa (de plástico) con los circuitos adheridos, pero las placas deben tener determinadas temperaturas: Si se sobre pasa demasiado dichas temperaturas: valores objetivos, las placas se pueden dañar. Estas condiciones de temperaturas deben alcanzar las placas en diversos puntos (valores objetivos) son: Y1, Y2, Y3, Y4, Y5, Y6.

Los datos se presentan a continuación:

X1	X2	X3	Y1	Y2	Y3	Y4	Y5	Y6
40	200	250	139	103	110	110	113	126
120	200	250	140	125	126	117	114	131
40	450	250	184	151	133	147	140	147
120	450	250	210	176	169	199	169	171
40	325	150	182	130	122	134	118	115
120	325	150	170	130	122	134	118	115
40	325	350	175	151	153	143	146	164
120	325	350	180	152	154	152	150	171
80	200	150	132	108	103	111	101	101
80	450	150	206	143	138	176	141	135
80	200	350	183	141	157	131	139	160
80	450	350	181	180	184	192	175	190
80	325	250	172	135	133	155	138	145
80	325	250	190	149	145	161	141	149
80	325	250	180	141	139	158	140	148

El diseño del experimento es el modelo desarrollado por Box - Behnken; para 3 factores y 2 niveles para cada factor.

Del Castillo et al. (1996), desarrollaron una nueva función de solución de la función de deseabilidad que es superior a la de Harrington, y a la de Hooke-Jeeves. Los valores objetivo utilizados son: Y1 = 190; Y2 = 185; Y3 = 185; Y4 = 190; Y5 = 185; Y6 = 185; habiéndose obtenido como resultados para los parámetros de entrada: X1 = 84,15 Ft3/min, X2 = 450 °C; X3 = 329,8 °C; y con ellos para los valores objetivos los siguientes: Y1 = 186,9 °C; Y2 = 173,0 °C; Y3 = 170,1 °C; Y4 = 190,0 °C; Y5 = 170,9 °C; Y6 = 182,4 °C.

PROBLEMAS MULTIRESPUESTA Y SOLUCIÓN CON REDES NEURONALES

Aplicando redes neuronales a los mismos datos se siguió la metodología sugerida por Lee-Ing Tong y Kun-Lin Hsieh, en su artículo "A Novel mean of Applying Neural Networks to Optimize the Multiresponse Problem", publicado en el Quality Engineering, Vol.13, N° 1; son: X1 = 7,674 Ft3/min; X2 = 477,112 °C; X3 = 348,118 °C; y con ellos para los valores objetivo los siguientes: Y1 = 187,4 °C; Y2 = 181,0 °C; Y3 = 178,6 °C; Y4 = 190,3 °C; Y5 = 173,1 °C; Y6 = 186,1 °C. Para ello se aplicaron redes neuronales BP, con arquitectura 6-5-3 para la Red Inversa y 3-5-6 para la Red Directa.

En el presente trabajo se ha probado con la información proporcionada las siguientes redes con BP y los siguientes algoritmos de entrenamiento: Basic gradient descent traingd, Basic gradient with momentum traingdm, Adaptive rate traingdx, Resilient BP trainrp, Fletcher - Reeves conjugate gradient algorithm, traincfg, Powell - Beale conjugate gradient algorithm traincgb, Polak - Ribiere conjugate gradient

algorithm traincgp, Scaled conjugate gradient algorithm trainscg, BFGS quasi - Newton method trainbfg, One step secant method trainoss, Leven - Marquart algorithm trainlm, Bayesian regularization trainbr y newgrnn. Los menores MSE fueron los obtenidos con BP traingdm y newgrnn. La arquitectura que dio los mejores resultados fue similar a la recomendada por Tong y Hsieh.


La metodología fue la siguiente:

Paso 1. Encontrar la red neuronal que con los datos de salida como entradas permita obtener los valores objetivos, Red Inversa. Obtenida la red entrenada se aplican los datos objetivo para obtener los valores de entrada optimizados.

Paso 2. Encontrar la red neuronal que con los datos de entrada permita obtener los valores objetivo. Obtenida la red entrenada se aplican los datos de entrada optimizados para obtener los valores objetivos optimizados.


En el siguiente gráfico se aprecia el método seguido:

Paso 1:
Datos de X1...X3 como salida



Datos de Y1...Y6 como entrada

Paso 2:
Datos de Y1...Y6 como salida



Datos de X1...X3 como entrada

Los resultados obtenidos son:

Aplicando la Red Neuronal BP traingdm se obtuvo X1 = 74,7560 Ft3/min; X2 = 482,9671 °C; X3 = 322,0778 °C; y con ellos para los valores objetivo los siguientes: Y1 = 188,3414 °C; Y2 = 181,7106 °C; Y3 = 184,8623 °C; Y4 = 195,5162 °C; Y5 = 175,3033 °C;

>>> Aplicación de Redes Neuronales para Optimizar Problemas Multirespuesta en Mejora de la Calidad

Cuadro 1. Comparación de valores

F.Des. Castillo	Factores Controlables X				Valores respuesta Y				
	X1	X2	X3	Y1	Y2	Y3	Y4	Y5	Y6
RN Tong	84.15	450	329.8	186.9	173	170.1	190	170.9	182.4
RN BP gdm . Cevallos	72.67	477.12	348.12	187.4	181	178.6	190.3	173.1	186.1
newgrnn Cevallos Objetivos	74.7560	482.9671	322.0778	188.3414	181.7106	184.8623	195.5162	175.3033	190.8334
	80	450	350	181	180	184	192	175	190
				190	185	185	190	185	185

Y6 = 190,8334 °C. Aplicando la Red Neuronal newgrnn se obtuvo X1 = 80 Ft3/min; X2 = 450° C; X3 = 350 °C; y con ellos para los valores objetivo los siguientes: Y1 = 181°C; Y2 = 180°C; Y3 = 184°C; Y4 = 192°C; Y5 = 175°C; Y6 = 190°C.

La comparación de los valores se muestra en el Cuadro 1. Aquí, se puede apreciar que la red desarrollada en el presente trabajo con BP traingdm, está más cerca de los valores objetivos que la Red desarrollada por Tong y Hsieng, que la red newgrnn y que lo calculado mediante la función de deseabilidad de Del Castillo et al. (1996). Si bien es cierto las 4 propuestas están cercanas a los valores objetivos y dentro de los límites; la desarrollada en el presente trabajo mediante el uso de BP gdm tiene 4 valores más cercanos a los valores objetivos, mientras que la propuesta de Tong y Hsieng, un valor y, la de Del Castillo, un valor. Asimismo, si se compara las otras 3 propuestas que usan redes neuronales con la de la función de deseabilidad de Del Castillo, todas son superiores, ya que están más próximas a los valores objetivos. Es decir, el trabajo con Redes Neuronales permite llegar a valores más cercanos al objetivo en los casos de Problemas de Optimización Multirespuesta.

CONCLUSIONES

Este estudio ratifica la ventaja de lo propuesto por Tong y Hsieh en lo que se refiere a la metodología de trabajar con la Red Neuronal Inversa y luego con la Directa. Asimismo, la ventaja que tiene de trabajar con Redes Neuronales frente a los métodos de regresión múltiple ajustados, la función de deseabilidad que fuera desarrollada por Harrington y mejorada por Del Castillo et al. (1996) y otros métodos convencionales, para la solución de Problemas de Optimización Multirespuesta.

La metodología desarrollada realiza el trabajo de resolver problemas multirespuesta más fácil, lo cual

permite su uso en la mejora de la calidad de manera más continua, ya que no se requiere de profundos conocimientos estadísticos. Lo puede realizar cualquier ingeniero de planta sin necesidad de tener amplios conocimientos de estadística

Se apertura un amplio campo de estudios de investigación en lo que se refiere a la mejora de la calidad con el uso de redes neuronales, sobre todo en lo que respecta a características de calidad cualitativas; donde las redes neuronales que se tienen que utilizar son distintas a las vistas hasta el momento.

BIBLIOGRAFIA

1. Del Castillo, E, Montgomery,D.C. y McCarville, D.R. (1996). *Modified Desirability Functions for Múltiple Response Optimization*. Journal of Quality Technology, 28 (3), 337-345.
2. Derringer, G y Suich, R. (1998). *Simultaneous Optimization of Several Response Variables*. Journal of Quality Technology, 12, 214-219.
3. Kaufmann, A y Gil, J. (1995). *Grafos Neuronales para la Economía y la Gestión de Empresas*. Editorial Pirámide.
4. Khuri, A.I. y Conlon, M. (1981). *Simultaneous Optimization of Multiple Responses Represented by Polinomial Regression Functions*. Technometrics, 23, 363-375.
5. Lee-Ing Tong y Kun-Lin Hsieh. (2001). *A Novel Means of aplying Neural Networks to Optimize the Multiresponse Problem*. Quality Engineering, 13 (1), 11-18.
6. Martin Del Brio, B. y Sanz, A. (2002). *Redes Neuronales y Sistemas Difusos*. Editorial Alfaomega. Madrid, España.