

# MEJORA DE LA CALIDAD DE PROCESOS CON REDES NEURONALES, ALGORITMOS GENÉTICOS Y LÓGICA DIFUSA

Juan M. Cevallos  
Universidad San Ignacio de Loyola

---

Saber y Hacer

Revista de Ingeniería de la USIL

Vol. 1, N° 2, Segundo semestre 2014. pp. 34-46

---

“Mejora de la calidad de procesos con redes neuronales, algoritmos genéticos  
y lógica difusa“

Juan M. Cevallos<sup>1</sup>

Universidad San Ignacio de Loyola

Recibido: 02.06.14

Aprobado: 10.08.14

---

<sup>1</sup> Magister en Ingeniería Industrial. Doctor en Ingeniería. Ingeniero en Industrias Alimentarias. Profesor de la Facultad de Ingeniería de la Universidad San Ignacio de Loyola. E-mail: [juanmanuelcevallos@gmail.com](mailto:juanmanuelcevallos@gmail.com)

# RESUMEN

---

En muchos casos de mejora de la calidad de productos o procesos se requiere optimizar varias respuestas simultáneamente. Un enfoque clásico es aplicar el Diseño de Experimentos (DDE), modelos de regresión múltiple para estimar las relaciones entre las respuestas y factores controlables; luego se combinan las diferentes respuestas con una función de deseabilidad y, finalmente, se optimizan los factores controlables. Sin embargo, puede ocurrir que la relación entre respuestas y factores controlables sea demasiado compleja para estimar la relación con estos métodos; por ejemplo,

una relación altamente no lineal. Un enfoque alternativo propuesto es el uso de redes neuronales artificiales RNA para estimar funciones de respuesta; en el caso de que se cuente con variables cualitativas, se les procesa con lógica difusa LD, y en la fase de optimización se utilizan algoritmos genéticos AG. Se presenta un ejemplo de optimización de un proceso de respuestas múltiples para comprobar la propuesta.

**Palabras clave:** Diseño de Experimentos, mejora de la calidad, redes neuronales artificiales, algoritmos genéticos, lógica difusa.

# ABSTRACT

---

In many cases, when trying to improve the quality of products or processes, it is necessary to simultaneously optimize multiple responses. A classic approach is to apply the Design of Experiments (DOE), multiple regression models to estimate the relationship between the responses and the controllable factors; then, combine the different responses with a desirability function and finally the controllable factors are optimized. However, it may happen that the relationship between controllable factors and responses is too complex to estimate the relationship with these methodologies;

for example, a highly nonlinear relationship. A proposed alternative approach is the use of artificial neural networks (ANN) to estimate response functions; in the event of having qualitative variables, they are processed with fuzzy logic (FL), and in the optimization phase genetic algorithms (GA) are used. An example of optimizing a process of multiple responses is presented to validate this proposal.

**Keywords:** Design of Experiments, quality improvement, artificial neural networks, genetic algorithms, fuzzy logic.

# INTRODUCCIÓN

---

El Diseño de Experimentos (DDE) es un método de mejora de la calidad eficaz recomendado por muchos expertos en optimización del desempeño de procesos y productos. El DDE ayuda a investigar los efectos de los factores controlables y no controlables sobre una o más respuestas de interés. El objetivo del DDE es determinar el conjunto óptimo de valores de los factores controlables de tal forma que se alcancen las características de calidad deseadas con el mínimo de variación.

Por lo general, la evaluación de la calidad de productos o procesos involucra el estudio simultáneo de varias características de calidad con cada una teniendo su propia importancia relativa para los consumidores. Este problema es comúnmente referido como un problema de optimización de respuestas múltiples. En este tipo de problema, la meta es determinar el conjunto de valores de los factores controlables que permitan la mejor combinación de respuestas (Montgomery, 2006). Cuando los procesos son complejos, el DDE tiene limitaciones y se utilizan métodos heurísticos. De esto es justamente lo que trata el presente trabajo. Se desarrolla una propuesta alternativa para situaciones complejas mediante el uso de redes neuronales artificiales, algoritmos genéticos y lógica difusa, lo cual se conoce como Soft Computing.

Los procesos complejos se caracterizan, entre otras cosas, por que las relaciones entre variables no son lineales porque la optimización de varias funciones objetivo se realiza a la vez, que incluso pueden ser contradictorias entre sí, y porque la solución no es una sola, sino un conjunto de

valores, por lo general un plano (Deb, 2013). Asimismo, se tiene dificultad para calcular las derivadas respectivas de las funciones, con lo que se dificulta la aplicación del método tradicional de optimización.

Otro aspecto fundamental a tener en cuenta es lo sostenido por Rajasekaran y Vijayalakshmi (2011), quienes trabajan con valores imprecisos, inciertos y parcialmente verdaderos. Singh (2010), cuando se refiere al *soft computing*, destaca la ventaja que tiene porque es tolerante a la imprecisión, incertidumbre, verdad parcial y aproximación, cosa que no soportan los métodos de cálculo tradicionales.

En la literatura existen diversos métodos para optimización de problemas de respuestas múltiples. Ortiz et al. (2004) sostienen que hay tres métodos básicos. El desempeño de cada método depende del tamaño y la complejidad del problema. El primero consiste en la superposición de curvas de contorno de cada respuesta, y con base en ellos se encuentra la región de interés que por las diferentes respuestas es satisfecha. El problema principal con este enfoque es que no se puede identificar la solución más importante. Myers y Montgomery (2009) manifiestan que dicho enfoque es eficaz solo cuando se tienen pocos factores controlables. El segundo mencionado por Ortiz et al. (2004) consiste en formular el problema en la forma de un problema de optimización restringida. Kim y Lin (2006) se refieren a este método como un enfoque basado en prioridades que utiliza la respuesta más importante como la función objetivo, y las demás respuestas son consideradas como restricciones.

Ejemplos del mencionado enfoque se pueden hallar en trabajos sobre metodología de superficie de respuesta, como los de Kim y Lin (2006). La principal desventaja de estos enfoques es que no consideran de forma simultánea todas las respuestas. El tercer método, y el más general, consiste en enfoques que utilizan los siguientes tres pasos para encontrar la solución. Primero, construir modelos para las respuestas de interés. Segundo, combinar los modelos en un solo valor escalar, y tercero, optimizar el modelo de una sola variable por medio de un método de optimización.

El método de mínimos cuadrados (MC) es el enfoque más común para llevar a cabo el primer paso, es decir, la construcción del modelo. Para el segundo paso se pueden aplicar diferentes técnicas, como son funciones de deseabilidad (Myers y Montgomery, 2002), funciones de distancia (Khuri y Cornell, 1996), funciones de pérdida del error cuadrático (Vining, 1998) y la proporción de conformidad (Chiao y Hamada, 2001). El método de las funciones de deseabilidad es el más práctico de aplicar, y la ventaja sobre las otras tres técnicas es su capacidad para considerar la correlación que pueda existir entre las respuestas. Para el tercer paso, el método de optimización depende de las propiedades de la variable del modelo de la superficie de respuesta. Las técnicas de búsqueda, tales como la de Hooke-Jeeves, propuesta por Derringer y Suich en Myers y Montgomery (2002), son comúnmente utilizadas para funciones de superficie de respuesta no diferenciables. Para las funciones objetivo diferenciables se pueden considerar los métodos basados en gradiente, como gradiente reducido generalizado (GRG) [Del Castillo et al., 1996]. Asimismo, procedimientos heurísticos de búsqueda,

tales como los algoritmos genéticos (AG), el recocido simulado o la búsqueda tabú, pueden aplicarse a superficies altamente no lineales y complejas (Ortiz, et al., 2004; Singh, 2010).

Estos métodos heurísticos son los más prometedores hasta ahora para abordar los problemas de optimización de respuesta múltiple. El principal problema de estos métodos se presenta cuando el error cuadrado medio (MSE) de los modelos de regresión es alto. En este trabajo se desarrolla un enfoque basado, primero, en redes neuronales artificiales (RNA) para los problemas en que los modelos de regresión dan valores altos de MSE. El uso de las RNA nos ayuda en la detección de los factores controlables significativos de cada respuesta y, a continuación, para calcular la relación entre dicha respuesta y los factores controlables significativos. Otro problema que se presenta es que se encuentran respuestas cualitativas, que no pueden ser convenientemente representadas numéricamente. Por ello se presenta un procedimiento basado en lógica difusa para abordar el problema con respuestas cualitativas. Finalmente, se optimiza con el uso de algoritmos genéticos (AG).

# MÉTODO

## Enfoque propuesto

El enfoque propuesto sigue básicamente los mismos tres pasos para el tercer método mencionado antes. Se utilizan redes neuronales (RNA) para estimar la relación entre los factores controlables como las entradas y las respuestas como las salidas, en la primera fase; lógica difusa para tratar las variables cualitativas, en la segunda fase, y algoritmos genéticos (AG) como una potente herramienta de optimización, en la fase de optimización. Este procedimiento nos permite tomar ventaja de las capacidades de las redes neuronales para la aproximación de la función, del potencial de la lógica difusa para representar variables cualitativas y, también, de la aptitud de los AG en la optimización no lineal y compleja de las funciones. Para las respuestas cualitativas se realizan dos etapas de preprocesamiento: primero, la expresión lingüística y, luego, se transforma en vectores, utilizando la lógica difusa, de modo que puedan ser analizadas por las redes neuronales.

Se utilizan RNA para aproximar las relaciones entre las variables. Dependiendo de qué tipo de RNA se use, existen diferentes parámetros que ajustar, pero el concepto común compartido es que todas necesitan ser entrenadas. Se utilizan ejemplos, datos patrón, para entrenar la red neuronal. Cada ejemplo se compone de un par de datos, entrada-salida: una señal de entrada y su correspondiente respuesta deseada para la red neuronal. Así, un conjunto de ejemplos representa el conocimiento sobre el tema de interés (Haykin, 1994). Dados los datos para el diseño de una red neuronal, en primer lugar se selecciona una adecuada arquitectura para la red neuronal. En segundo lugar, un subconjunto de los ejemplos se usa para entrenar la red

por medio de un algoritmo de aprendizaje adecuado, y en tercer lugar, el desempeño de la red entrenada se prueba con datos que no se han utilizado inicialmente (generalización).

## Diseño del experimento

El enfoque propuesto se inicia con el diseño de un experimento. El diseño experimental nos ayuda a recoger los datos necesarios para la formación de las redes neuronales. Se usan diseños de metodología de superficie de respuesta (MSR), como el diseño compuesto central (CCD), debido a su capacidad para proporcionar la información requerida mediante la cobertura del espacio experimental. Tales diseños ayudan a las redes neuronales a aproximar la función del proceso.

## Respuestas cualitativas

Respuestas cualitativas, en forma de expresiones metalingüísticas como “muy bueno”, “bueno”, “medio”, etc.; es decir, se definen conjuntos difusos. En la definición de conjuntos difusos, las opiniones de los expertos son comúnmente consideradas. Este es uno de los pasos más importantes en la fuzificación de una variable cualitativa. La fuzificación de una respuesta cualitativa significa definir diferentes funciones de membresía, para diferentes valores cualitativos, indicando que las respuestas pertenecen a un dominio predefinido (Rajasekaran, 2003). Las RNA no son capaces de procesar los conjuntos difusos en la forma de funciones de pertenencia o membresía. Por ello, se alimenta a las redes neuronales con la información en la forma de vectores. Para eso, el dominio de los conjuntos difusos se divide en “n” intervalos

iguales y en  $n+1$  puntos de resultados. Los grados de pertenencia están representados por un vector con  $n+1$  elementos. El vector de  $n+1$  elementos es una aproximación de la función de pertenencia. Al aumentar el valor de “ $n$ ” resultará en una mejor aproximación. La determinación de un valor apropiado para “ $n$ ” depende de la naturaleza de la función de pertenencia.

### **Aplicación de una red neuronal para la estimación de la respuesta**

.....

En esta fase, una red neuronal se entrena para aproximar su relación con los factores controlables. La salida de la red neuronal entrenada es igual al número de las respuestas. Las entradas para estas redes son factores controlables y las salidas son respuestas. La capa de salida de la red tiene una neurona por respuesta cuantitativa y una por respuesta cualitativa; en cada respuesta cualitativa, considerar el número de alternativas de las variables cualitativas, “ $n$ ”. Para el entrenamiento se dividieron los datos en tres grupos: entrenamiento, validación y prueba.

#### **a. Identificación de factores controlables significativos para cada respuesta**

Antes del entrenamiento de la red, los factores significativos para cada respuesta tienen que ser identificados en forma de un subconjunto de todos los factores controlables que producen el mínimo MSE. Las RNA perceptrón multicapa con algoritmo de aprendizaje backpropagation se usaron con este objetivo. El MSE para los datos de prueba se utiliza como un criterio para comparar diferentes subconjuntos de factores controlables ( $x_i$ ,  $i = 1, \dots, k$ ). A través de este procedimiento, los modelos completos, incluyendo todos los factores controlables y todos sus subconjuntos de modelos con  $k-1$  elementos, modelos con  $k-2$  elementos, etc.,

pueden ser comparados entre sí. El modelo que produce el más bajo MSE para los datos de prueba contiene los factores significativos. Si la diferencia entre el modelo completo y un modelo de subconjunto no es significativa, se prefiere el modelo completo.

#### **b. Diseño de RNA más adecuada para estimar las respuestas**

Después de identificar los factores significativos para cada respuesta, la mejor red con el menor MSE será diseñada. En este paso se pueden considerar las redes perceptrón multicapa (MLP) o redes de base radial (RBF) para modelar la relación entre las respuestas y sus correspondientes factores significativos. Para aprobar el entrenamiento adecuado de la red, la salida de la red para los datos de entrenamiento debe ser comparada con los datos deseados obtenidos del experimento inicial.

#### **Optimización con algoritmos genéticos (AG)**

.....

Un AG es elegido para llevar a cabo la optimización por dos razones. En primer lugar, el gradiente basado en métodos de optimización tales como GRG no se puede utilizar debido a que requiere superficies de respuesta para calcular el gradiente y la dirección de mejoramiento. Sin embargo, cuando las redes neuronales se usan, no hay ninguna superficie de respuesta. En segundo lugar, el AG se conoce como un método de búsqueda heurístico potente para la optimización de funciones no lineales y complejas. Un AG tiene distintos parámetros cuyos valores deben ser determinados antes de iniciar la fase de optimización. Diferentes autores, entre ellos Ortiz et al. (2004), han propuesto el uso de diseños de experimentos robustos para determinar el mejor conjunto de los parámetros del AG. Por lo tanto, tenemos que incorporar un diseño experimental robusto para encontrar los mejores valores de los parámetros.



# RESULTADOS

**Ejemplo aplicativo.** Los datos de este ejemplo han sido obtenidos del trabajo de Bhol, et al. (2011) y se refieren a un proceso de taladrado. Los factores controlables, entrada, son velocidad del eje  $X_1$  (rpm), alimentación  $X_2$  (mm/rev), y las respuestas, salida, son desgaste del flanco  $Y_1$  (mm), fuerza de empuje  $Y_2$  (N) y torque  $Y_3$  (N-

m). Además, se ha agregado una respuesta cualitativa, condición aparente,  $Y_4$ , con las alternativas poco (p), medio (m) y bastante (b). Se busca minimizar las respuestas cuantitativas y maximizar la cualitativa. Los valores del diseño de experimentos se presentan en la tabla 1.

**Tabla 1**  
**Factores controlables y respuestas del diseño experimental, valores codificados**

$X_1$	$X_2$	$Y_1$	$Y_2$	$Y_3$	$Y_4$
0.1	0.1	0.1	0.614	0.543	p
0.1	0.42	0.35	0.728	0.811	p
0.1	0.633	0.4	0.745	0.841	p
0.1	0.9	0.45	0.792	0.9	p
0.274	0.1	0.4	0.528	0.528	m
0.274	0.42	0.6	0.694	0.702	m
0.274	0.633	0.65	0.807	0.716	m
0.274	0.9	0.9	0.9	0.825	m
0.622	0.1	0.15	0.1	0.1	b
0.622	0.42	0.2	0.33	0.202	b
0.622	0.633	0.3	0.52	0.284	b
0.622	0.9	0.3	0.697	0.396	b
0.9	0.1	0.1	0.137	0.203	b
0.9	0.42	0.2	0.23	0.152	b
0.9	0.633	0.2	0.245	0.192	b
0.9	0.9	0.4	0.283	0.211	b
0.173	0.1	0.1	0.717	0.567	p
0.173	0.167	0.3	0.728	0.613	p
0.173	0.42	0.3	0.753	0.691	p
0.42	0.1	0.3	0.373	0.36	p
0.42	0.167	0.35	0.424	0.496	m
0.42	0.42	0.4	0.575	0.575	m
0.9	0.167	0.1	0.171	0.136	m
0.1	0.167	0.2	0.657	0.657	m
0.173	0.633	0.5	0.76	0.76	b
0.173	0.9	0.6	0.785	0.785	b
0.274	0.167	0.4	0.543	0.543	b
0.42	0.633	0.4	0.65	0.65	b
0.42	0.9	0.5	0.737	0.737	b
0.622	0.167	0.2	0.195	0.195	b

**Fuente:** Datos obtenidos del artículo de Bhol, J. et al; "A Neuro Genetic Approach for Multi-Objective Optimization of Process Variables in Drilling", International Journal of Technology and Engineering System IJTES.

Para generar los valores cualitativos en la forma de expresiones multilingüísticas para  $Y_4$  se usó el intervalo de 30 a 60, el mismo que se divide en tres secciones cuyas correspondientes expresiones lingüísticas son utilizadas como sigue:

$Y_4 < 40$ : malo

$40 < Y_4 < 50$ : medio

$Y_4 > 50$ : bueno

Seguidamente, la respuesta cualitativa  $Y_4$  es fuzificada. Tres conjuntos difusos y sus funciones de pertenencia se definen a continuación:

$Y_4$  Condición aparente

$T(x)$  (bueno, medio, malo)

$U$  [30,60]

$$\mu_{malo}(Y_4) = \frac{1}{1 + \exp\left(\left(\frac{1}{3}\right)(Y_4 - 30)\right)}$$

$$\mu_{medio}(Y_4) = \exp\left(-\frac{(Y_4 - 45)^2}{2(5)^2}\right)$$

$$\mu_{bueno}(Y_4) = \frac{1}{1 + \exp\left(\left(-\frac{1}{3}\right)(Y_4 - 50)\right)}$$

Posteriormente, con el fin de alimentar estas funciones de pertenencia a las redes neuronales, se deben expresar como un vector. Para ello, el intervalo [30, 60] se dividió en tres de secciones iguales ( $n = 3$ ). De acuerdo con lo mencionado en el método, los cuatro ( $n+1$ ) elementos de los vectores de los tres conjuntos difusos se muestran en la tabla 2.

**Tabla 2**  
**Vectores relevantes para los tres conjuntos difusos**


Malo	Medio	Bueno
0.75	0.33	0.00
0.50	0.66	0.25
0.25	0.66	0.50
0.00	0.33	0.75

**Fuente:** Valores de Vectores relevantes para los tres conjuntos difusos obtenidos por el autor aplicando Lógica Difusa.

Las mejores redes con las cuatro respuestas son RNA perceptrón multicapa MLP con el algoritmo de entrenamiento backpropagation con la función Levenberg-Marquardt. Las funciones de activación de las capas de neuronas ocultas en todas las redes son tangente sigmoidea tansig. La red que mejor desempeño tuvo es la de 14 neuronas en la capa oculta [2, 14, 4], ya que posee el menor MSE (ver figura 1).

**Figura 1**

**Variación del cuadrado medio del error MSE de las RNA con diferente N° de neuronas**



**Fuente:** Variación del cuadrado medio del error MSE de las RNA con diferentes n° de neuronas, obtenida del software MATLAB aplicado.

El resultado obtenido de las RNA se aplicó a algoritmos genéticos multiobjetivo, como entrada. Se probaron varias alternativas, y el mejor resultado se obtuvo con fracción de Pareto, 0.2, con 50 generaciones, un tamaño de población de 97 y con función de medición de distancia “fenotipo”. Los demás factores

de Matlab R 2012b para algoritmos genéticos multiobjetivo se mantuvieron en los valores por default. Así, los valores obtenidos son:  $Y1 = 0.128$ ,  $Y2 = 0.136$ ,  $Y3 = 0.138$  e  $Y4 = 0.55$  (b), que corresponde a los  $X1 = 0.900$  y  $X2 = 0.103$ .

# DISCUSIÓN

---

En este trabajo se propone un enfoque para la optimización de los problemas de respuesta múltiple con o sin respuestas cualitativas. El enfoque considera una red neuronal RNA para estimar la relación de las salidas con los factores controlables, lógica difusa para tratar las variables cualitativas, y un algoritmo genético (GA) para realizar la optimización. Debe tenerse presente que el resultado obtenido de las redes neuronales es un conjunto de relaciones de pesos y funciones de transferencia, que constituyen las redes neuronales; dicho resultado se transforma en vectores y se introduce como datos para el algoritmo genético, lo cual realiza de manera automática el software respectivo. El enfoque propuesto es novedoso debido a tres aspectos principales. En primer lugar, se utilizan redes neuronales para estimar la relación entre las respuestas de interés y los factores controlables. En segundo lugar, se transforman los datos de las variables cualitativas en cuantitativos mediante el uso de la lógica difusa. Por último, se aproxima el óptimo con algoritmos genéticos.

El desempeño del enfoque propuesto fue evaluado a través del ejemplo de un proceso. Es de notar que el enfoque de optimización propuesto permitió minimizar tres respuestas y maximizar otra que era cualitativa. Los criterios de selección de las mejores redes neuronales son los mínimos cuadrados del error, y para los algoritmos genéticos se minimizan las medias de las respuestas. Además, se puede extender el enfoque para incluir el efecto de la dispersión de las respuestas. En estas situaciones son necesarias repeticiones para estimar la desviación estándar de distintas respuestas para conjuntos diferentes de factores controlables. Por otro lado, la red neuronal obtenida y el correspondiente algoritmo genético nos pueden permitir predecir resultados dados los valores de los factores controlables.

# REFERENCIAS

---

- Bhol J., et al. (2011). A Neuro-Genetic approach for multi-objective optimization of process variables in drilling. *International Journal of Technology and Engineering System (IJTES)*. Vol. 2, N° 1, pp. 89-94.
- Cheng C-B., et al. (2004). Neuro-Fuzzy and genetic algorithm in multiple response optimization. *Computers and mathematics with applications*. Vol. 44, N° , pp. 1503-1514.
- Chiao, C. y Hamada, M. (2001). Analyzing experiments with correlated multiple responses. *Journal of Quality Technology*. Vol. 33, N° 4, pp. 451-465.
- Deb, K. (2012). *Optimization for Engineering Design. Algorithms and examples*. Ed. PHI, pp. 294-300.
- Deb, K. (2013). *Multiobjective optimization using evolutionary algorithms*. Ed. Wiley, pp. 1-10.
- Del Castillo, et al. (1996). Modified desirability functions for multiple response optimization. *Journal of Quality Technology*. Vol. 28, N° 3, pp. 337-345.
- Haykin, S. (1994). *Neural networks*. Ed Macmillan College Publishing Company. New York (EE.UU).
- Khury, A. y Cornell, J. (1996). Response surfaces. Designs and analysis. Ed. Dekker, 2da edición, pp. 282-293.
- Kim, K.J. y Lin, D.K.J. Dual response surface optimization: A fuzzy modeling approach. *Journal of Quality Technology*. Vol. 30, N° 1, pp. 1-10.
- Myers, R. y Montgomery, D. (2002). *Response surface methodology: Process and product optimization using designed experiments*. Ed. Wiley, 2da edición, EE.UU., pp. 253-265.
- Montgomery, D. (2006). *Diseño y análisis de experimentos*. Ed. Wiley, 4ta edición, México, pp. 423-428.
- Ortiz F. et al. (2004). A genetic algorithm approach to multiple response optimization. *Journal of Quality Technology*. Vol. 36, N° 4, pp. 432-450.
- Singh, I. (2010). *Soft computing. Neural networks, fuzzy logic, genetic algorithm and probabilistic reasoning*. Ed. Khanna Book, pp. 545-555.
- Vinning, G (1998). A compromise approach to multiresponse optimization. *Journal of Quality Technology*. Vol. 30, N° 4, pp. 309-313.

