

OPTIMIZACIÓN DE CRITERIOS DE ACEPTACIÓN DE PRODUCTOS MEDIANTE UNA RED NEURONAL ARTIFICIAL

OPTIMIZATION OF PRODUCT ACCEPTANCE CRITERIA THROUGH AN ARTIFICIAL NEURONAL NETWORK

Elías Cano Cisneros

Tecnológico Nacional de México / IT de Celaya, México
elias_cano05@hotmail.com

Moisés Tapia Esquivias

Tecnológico Nacional de México / IT de Celaya, México
moises.tapia@itcelaya.edu.mx

Alicia Luna González

Tecnológico Nacional de México / IT de Celaya, México
alicia.luna@itcelaya.edu.mx

José Alfredo Jiménez García

Tecnológico Nacional de México / IT de Celaya, México
alfredo.jimenez@itcelaya.edu.mx

Manuel Darío Hernández Ripalda

Tecnológico Nacional de México / IT de Celaya, México
dario.hernandez@itcelaya.edu.mx

Recepción: 9/mayo/2020

Aceptación: 1/diciembre/2020

Resumen

Desde los años 90's, las empresas que se encuentran a un nivel de alta competencia es por un mayor enfoque en calidad. Una de las formas de conseguirlo es a través de la mejora de la calidad del producto para lograr la satisfacción de los clientes. Sin embargo, no todas las empresas son capaces de alcanzar esta mejora. Uno de los problemas más usuales para mejorar la calidad en las industrias es la variabilidad presente en los procesos originando el rechazo del producto. En este artículo se propone una alternativa novedosa para optimizar los criterios de aceptación del producto, aplicando la metodología Shainin para identificar la causa raíz y redes neuronales para predecir resultados. El alcance de la investigación se limita a un caso de estudio de bombas de inyección que presentaban rechazo por

vibración. Como resultado se identifica la causa raíz del problema y optimizan los criterios de aceptación.

Palabras Clave: Criterios de Aceptación, Metodología Shainin, Optimización, Predicción de Resultados, Red Neuronal.

Abstract

Since the 90's, companies that are at a high level of competition is due to a greater focus on quality. One of the ways to achieve this is through the improvement of product quality to achieve customer satisfaction. However, not all companies are capable to achieve this improvement. One of the most common problems to improve quality in the industries is the variability present in the processes causing the rejection of the product. This article proposes a novel alternative to optimize the product acceptance criteria, applying the Shainin methodology to identify the root cause and neural networks to predict results. The scope of the investigation is limited to a case study of injection pumps that presented vibration rejection. As a result, the root cause of the problem is identified and the acceptance criteria are optimized.

Keywords: *Criteria of Acceptance, Neural Network, Optimization, Results Prediction, Shainin Methodology.*

1. Introducción

Desde los años 90's las empresas de éxito y alcance mundial se han enfocado en la realización de grandes esfuerzos en mejorar su calidad como vía para incrementar su competitividad y rentabilidad [Zapata et al., 2012]. Calidad de clase mundial quiere decir proporcionar productos que satisfacen las necesidades y expectativas de los clientes a un coste más económico y eficiente para el cliente [Sánchez, 2019].

Todas las organizaciones están constituidas por procesos clave para la creación de valor para el cliente, los cuales deben mejorarse hasta niveles de calidad sin precedentes [Gutiérrez, 2010]. Un proceso de mala calidad es errático, costoso, inestable y no se puede predecir. En este sentido, la mala calidad no sólo trae como consecuencia clientes insatisfechos sino también mayores costos. Por lo tanto, no

es posible competir en calidad ni en precio, menos en tiempos de entrega [Gutiérrez et al., 2009].

La mayor dificultad para proporcionar al cliente productos con características de calidad perfectas es la variabilidad inherente a cualquier proceso de fabricación [Luceño et al., 2015]. Hemos de admitir la imposibilidad de fabricar dos productos exactamente iguales y, por lo tanto, en principio aceptaremos la posible variabilidad en los mismos [Vilar et al., 2005]. Pero, si la variabilidad es relativamente grande, las unidades producidas pueden ser inaceptables, o lo que es lo mismo, rechazadas o no-conformes a las especificaciones [Luceño et al., 2015].

Uno de los objetivos más importantes de la ingeniería de la calidad es la reducción sistemática de la variabilidad [González et al., 2016]. La reducción de la variabilidad en el proceso se puede lograr identificando, controlando y/o eliminando la causa raíz del problema. Esta identificación de la causa raíz se puede llevar a cabo con la ayuda de metodologías de resolución de problemas [Rey, 2003].

La metodología Shainin presenta muchas técnicas en una secuencia de resolución progresiva de problemas. Su principio fundamental es que en cualquier problema existe una causa dominante de variación conocida como Red X [Gelman et al., 2009]. La técnica o instrumento B (*Best*) vs C (*Current*) es una experimentación comparativa de productos que necesita tamaños de muestra extremadamente pequeños (generalmente tres B y tres C). Su propósito es determinar cuál de los dos productos es mejor en términos de calidad y confiabilidad [Bhote et al., 2000].

La implicación del presente trabajo de investigación consiste en el diseño de una red neuronal artificial que optimice los criterios de aceptación de un producto, en base a los datos obtenidos con la herramienta B vs C. Las redes neuronales pueden considerarse modelos de cálculo caracterizados por algoritmos muy eficientes que operan de forma paralela y permiten desarrollar tareas como el aprendizaje de patrones, la clasificación o la optimización [Flórez et al., 2008].

Las redes neuronales son empleadas dentro de procesos de optimización, pero se utilizan en conjunto con cualquier técnica de búsqueda. Porque la red neuronal es útil para la predicción del comportamiento de alguna variable. Por sí sola no establece un valor óptimo dentro de un proceso de optimización [González, 2016].

Por lo anterior, se propone desarrollar una red neuronal en conjunto con las herramientas de la metodología Shainin.

Las redes neuronales se inspiran en el cerebro humano para realizar una tarea o función. Dicha herramienta realiza cálculos a través de un proceso de aprendizaje. Así mismo, consiste en un conjunto de unidades de entrada/salida conectadas en las que cada conexión tiene un peso asociado [Lahoz-Beltrá, 2010]. En la fase de aprendizaje, la red aprende ajustando los pesos para predecir el resultado en base a las entradas dadas. Este peso es usado por la red como herramienta para resolver problemas [Haykin, 2009].

Existe una gran variedad de softwares para simulación de redes neuronales. Por ser el procedimiento más simple, rápido y económico, constituye la primera etapa en el desarrollo de la red. Además, es una solución muy versátil que permite predecir y tomar decisiones a problemas [Valero et al., 2013].

Se utiliza como instrumento de predicción de resultados una red multicapa con una función de activación de paso binario [Haykin, 2009], junto con una serie de variables definidas en el problema. Estas variables servirán como entradas de aprendizaje a la red neuronal. Con lo anterior, se busca obtener el resultado esperado, una optimización en los criterios de aceptación de un producto.

De esta manera, con la implicación y uso de las técnicas de la metodología Shainin se identifica la causa raíz de un problema de calidad. Por consiguiente, la red neuronal tendrá la tarea de procesar ciertos datos relacionados a la causa raíz de variación. Con estos datos, se buscará generar salidas que predigan si el producto será aceptado o rechazado. El resultado o impacto esperado por parte de los autores con el desarrollo de la presente investigación es mostrar de manera confiable la optimización de los criterios de aceptación de un producto mediante una red neuronal artificial. Identificando las variables a considerar mediante el uso y aplicación de la metodología de resolución de problemas Shainin.

2. Métodos

En este apartado se plantea el método a seguir para la optimización de los criterios de aceptación de productos, aplicando la metodología Shainin para la

solución de problemas y redes neuronales para la predicción de resultados. Para desarrollar el método se toma como referencia el artículo de Steiner et al. (2008) en el cual se describen las etapas de la metodología Shainin para la mejora de la calidad. Así mismo, se usa el artículo de Navlani (2019) donde se ejemplifican los pasos para implementar una red neuronal. Con lo anterior, se propone el siguiente método representado en la figura 1.

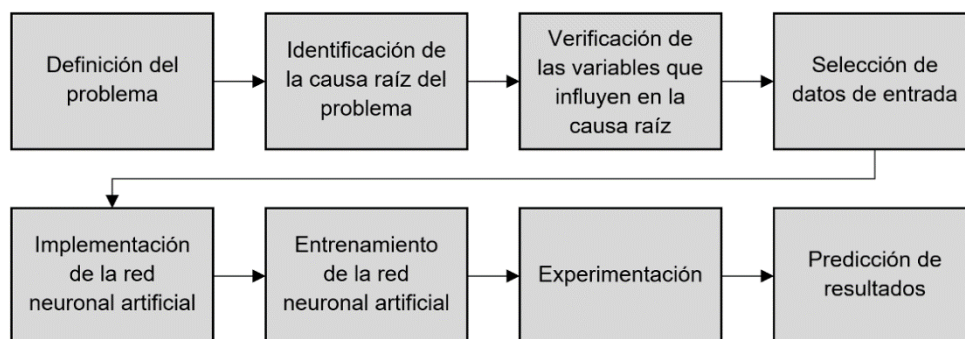


Figura 1 Método propuesto para la optimización de criterios de aceptación.

El método propuesto en la figura 1 muestra las etapas necesarias para la optimización de los criterios de aceptación de un producto. En resumen, se plantea implementar una red neuronal artificial en conjunto con una metodología de resolución de problemas. Las primeras etapas del método implican el uso y aplicación de la metodología Shainin para la identificación de la causa dominante de variación. Después, se promueve la verificación y selección de las variables que contribuyen a la causa raíz del problema. Dichas variables, representan las entradas de la red neuronal con el fin de entrenarla para predecir los resultados esperados.

Definición del problema de calidad

El propósito de la primera etapa del método es cuantificar la magnitud del problema seleccionado. Para hacer esto, monitoreamos la salida del proceso empleando pequeños muestreos (30 piezas o menos) de acuerdo a la metodología Shainin durante un período de tiempo por hora, diario o semanal. De tal modo que veamos el efecto de todas las grandes causas de variación, especialmente la causa dominante.

Identificación de la causa raíz del problema

Esta segunda etapa consiste en el uso y aplicación de la metodología Shainin con el fin de generar pistas sobre la causa dominante de variación, empleando primeramente como instrumento los planes de observación. Posteriormente, ir descartando una a una las variables sospechosas a través de pequeñas muestras y el uso de herramientas como el Isoplot para descartar el sistema de medición, y de la técnica B versus C para descubrir y validar la causa raíz del problema.

Verificación de las variables que influyen en la causa raíz

La finalidad de la tercera etapa consiste en cambiar los niveles o parámetros de una causa dominante en el experimento, dando como resultado el rango completo de la variación de salida.

La metodología Shainin recomienda un experimento de seis ejecuciones (llamado B versus C) con tres repeticiones para cada nivel. Su propósito es determinar que variables influyen en la causa dominante y se pueden mejorar en términos de calidad y confiabilidad.

Selección de datos de entrada

Una vez identificadas las variables que afectan la causa raíz, en esta cuarta etapa se toman los datos del experimento B versus C para ser las entradas de nuestra red neuronal artificial. Estos datos representan piezas buenas (*Best*) y piezas malas (*Current*) del proceso. Por lo cual, constituyen el rango completo de variación para que la red neuronal aprenda y sea capaz de predecir resultados confiables.

Implementación de la red neuronal artificial

Esta quinta etapa consiste en la elección del tipo o modelo de red neuronal artificial a utilizar de acuerdo con que características y parámetros se adapten al problema. Se empleará el uso del software libre "R" para la creación y construcción de la red neuronal como instrumento de predicción. Así mismo, es requerida la instalación de la biblioteca "neuralnet" en el programa para la correcta ejecución de la red.

Entrenamiento de la red neuronal artificial

En esta sexta etapa se realiza la base de datos de entrenamiento en el software R. En la base de datos se requieren dos tipos de atributos: características (datos de entrada) y la etiqueta binaria (datos de salida, 1 y 0 representando producto aceptado o rechazado respectivamente). Además, en esta misma etapa se construye el modelo clasificador de red neuronal a través del conjunto de argumentos de etiqueta y características, conjunto de datos, cantidad de neuronas en capas ocultas y cálculo de errores.

Experimentación

En la séptima etapa se busca como finalidad trazar o graficar la red neuronal creada con los datos de entrenamiento de la etapa anterior.

Se requiere que el error apreciado en la red sea el mínimo posible para obtener predicciones más confiables y precisas. Posteriormente, hay que crear un conjunto de datos de prueba con el propósito de experimentar y poder evaluar la efectividad de la red neuronal obtenida.

Predicción de resultados

La última y octava etapa consiste en predecir resultados en base a los datos de prueba anteriormente generados.

Las redes neuronales han demostrado constituir un instrumento de medición muy efectivo en la predicción de resultados. Aplicando una red neuronal para predecir los estados de "aceptado" o "rechazado", se optimizan los criterios de aceptación del producto.

3. Resultados

Los resultados se presentan en puntuaciones de probabilidad. Entonces, se convierten las probabilidades en clases binarias estableciendo un nivel de umbral. Si la probabilidad está por encima del valor de umbral, la salida está activada (1, producto aceptado), y si es menor que el umbral, la salida no está activada (0, producto rechazado).

Definición del problema de calidad

El problema seleccionado es un caso de estudio presentado por Shivdarshan et al. (2018) donde se tienen rechazos de bombas de inyección de combustibles (componente importante de cualquier motor). Tras el monitoreo del proceso, la figura 2 señala que el rechazo debido a la vibración de la barra de control es el segundo más alto, lo que resulta en una pérdida de producción.

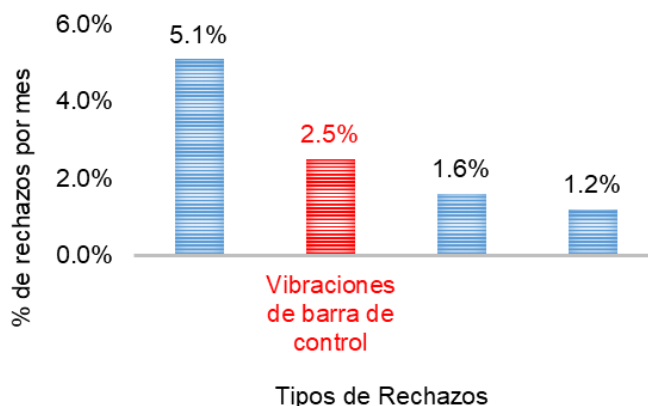


Figura 2 Porcentaje de rechazos por mes [Shivdarshan et al., 2018].

La definición del problema en la metodología Shainin se denomina *Green Y*. Por lo tanto, la *Green Y* para el proyecto actual es: 2.5% de rechazos mensuales por vibración en la barra de control de la bomba de inyección de combustible diésel

Identificación de la causa raíz del problema

Utilizando la metodología Shainin, no se encontró evidencia considerable que demuestre que el sistema de medición o el proceso de calibración alberguen la causa raíz. Claramente la causa raíz se encuentra en un componente (materia prima) presente en la bomba de inyección. Para encontrar el componente, se aplicó la técnica B vs C, se seleccionaron 3 bombas defectuosas e intercambiaron sus componentes con 3 bombas buenas. De manera que esta muestra de 6 bombas tiene la mayor diferencia en sus valores (la mayor variación). Después del intercambio, se identifican los siguientes componentes sospechosos en la bomba: Gobernador, Cubierta del gobernador, Brida de rodamiento y Árbol de levas. Estos componentes sospechosos se intercambiaron individualmente entre las bombas

buenas y malas en cada par, hasta que las bombas buenas se volvieron malas, y las bombas malas en buenas. El intercambio para un par se muestra en la figura 3. De la figura 3 se desglosa lo siguiente, al cambiar el árbol de levas entre la bomba buena y mala, la bomba defectuosa funciona correctamente y la bomba buena funciona mal. Lo que indica la presencia de la causa dominante de variación (conocida como Red X) en el árbol de levas.

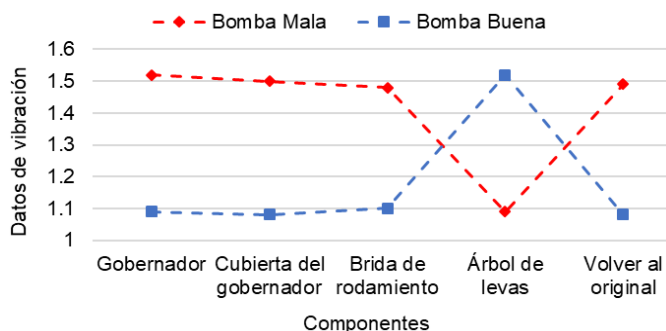


Figura 3 Resultados de B vs C o intercambio de componentes [Shivdarshan et al., 2018].

Verificación de las variables que influyen en la causa raíz

Analizando el árbol de levas entre las bombas buenas y las bombas defectuosas, se encuentra que la longitud total del árbol de levas es menor que la longitud de la carcasa de la bomba para las tres bombas defectuosas. La interferencia entre el árbol de levas y la carcasa de las bombas buenas y malas analizadas en el B vs C se muestra en la tabla 1.

Tabla 1 Resultados de interferencia.

Bombas de Inyección	Interferencia
Bomba Mala 1	-0.12
Bomba Mala 2	-0.17
Bomba Mala 3	-0.09
Bomba Buena 1	0.49
Bomba Buena 2	0.24
Bomba Buena 3	0.27

Se observa que la interferencia en una bomba defectuosa es negativa, lo que significa que la longitud total del árbol de levas es menor que la longitud de la carcasa de la bomba. Es decir, las variables que influyen en la causa raíz del

problema son las dimensiones de los componentes que conforman el árbol de levas.

Dichas variables son las siguientes:

- Longitud del árbol de levas
- Altura del cojinete de la carcasa del gobernador
- Espesor de la cuña
- Altura del cojinete de rodamiento

Selección de datos de entrada

Los datos de las variables que afectan la causa raíz representan las entradas para la red neuronal. Estos datos o dimensiones son tomados de las seis bombas de inyección que se usaron en el experimento B vs C. Como consistían en tres piezas buenas y tres malas, se tiene el rango completo de variación. La tabla 2 muestra las dimensiones en milímetros de las seis bombas analizadas. Las primeras cuatro columnas de dimensiones en la tabla 2 representan la longitud total del árbol de levas. La última columna indica la longitud de la carcasa de la bomba. La condición ideal es que la longitud de la carcasa de la bomba sea menor a la longitud total del árbol de levas y no al revés como sucede con las bombas defectuosas.

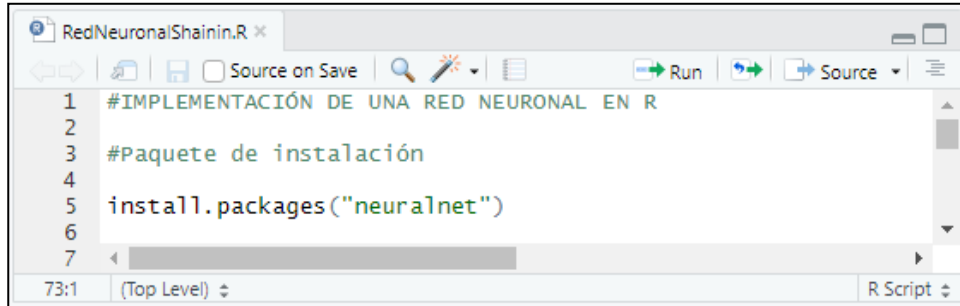
Tabla 2 Dimensiones de los componentes involucrados en la causa raíz.

Bomba	Espesor de la cuña	Longitud del árbol de levas	Altura del cojinete de la carcasa del gobernador	Altura del cojinete de rodamiento	Longitud de la carcasa de la bomba
BM 1	5.50	180.63	14.35	14.19	214.79
BM 2	5.54	180.22	14.68	14.15	214.76
BM 3	5.57	180.23	14.71	14.18	214.78
BB 1	5.78	180.74	14.54	14.20	214.77
BB 2	5.80	180.17	14.91	14.16	214.80
BB 3	5.81	180.16	14.92	14.18	214.80

Implementación de la red neuronal artificial

Se eligió como red neuronal artificial de trabajo una red multicapa con una función de activación de paso binario debido a que sus características fueron las que mejor se adaptaron al problema presentado en la experimentación. Se empleó el software R para la construcción e implementación de la red neuronal.

Por consiguiente, se instaló la biblioteca “neuralnet” en el software R como se muestra en la figura 4.

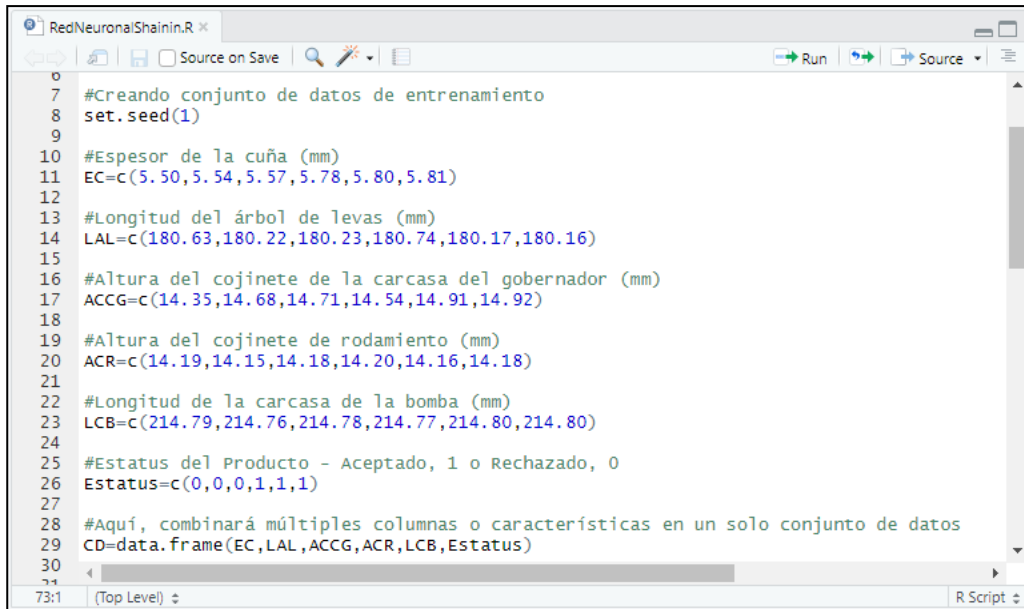


```
1 #IMPLEMENTACIÓN DE UNA RED NEURONAL EN R
2
3 #Paquete de instalación
4
5 install.packages("neuralnet")
6
7
```

Figura 4 Instalación de la biblioteca neuralnet para la implementación de la red.

Entrenamiento de la red neuronal artificial

Se creó un conjunto de datos para el entrenamiento de la red tomando como base las variables que influyen en la causa raíz del problema. La longitud del árbol de levas, la altura del cojinete de la carcasa del gobernador, el espesor de la cuña, la altura del cojinete de rodamiento y la longitud de la carcasa de la bomba representan el atributo de características o datos de entrada de la red, figura 5.

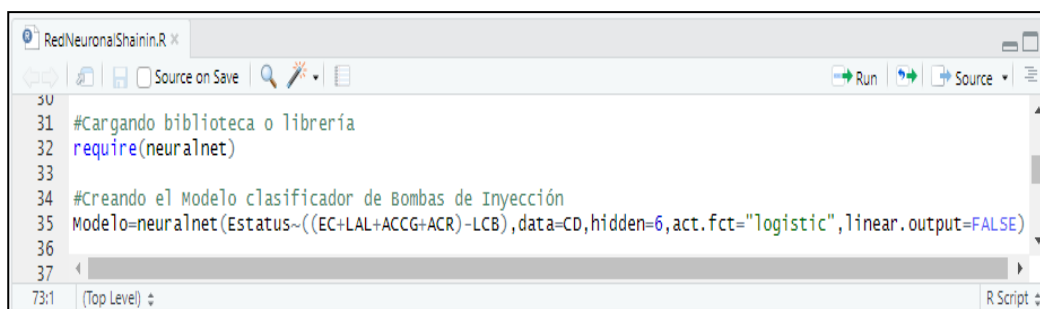


```
7 #Creando conjunto de datos de entrenamiento
8 set.seed(1)
9
10 #Espesor de la cuña (mm)
11 EC=c(5.50,5.54,5.57,5.78,5.80,5.81)
12
13 #Longitud del árbol de levas (mm)
14 LAL=c(180.63,180.22,180.23,180.74,180.17,180.16)
15
16 #Altura del cojinete de la carcasa del gobernador (mm)
17 ACCG=c(14.35,14.68,14.71,14.54,14.91,14.92)
18
19 #Altura del cojinete de rodamiento (mm)
20 ACR=c(14.19,14.15,14.18,14.20,14.16,14.18)
21
22 #Longitud de la carcasa de la bomba (mm)
23 LCB=c(214.79,214.76,214.78,214.77,214.80,214.80)
24
25 #Estatus del Producto - Aceptado, 1 o Rechazado, 0
26 Estatus=c(0,0,0,1,1,1)
27
28 #Aquí, combinará múltiples columnas o características en un solo conjunto de datos
29 CD=data.frame(EC,LAL,ACCG,ACR,LCB,Estatus)
30
```

Figura 5 Creación del conjunto de datos de entrenamiento.

En la figura 5 también se observa el atributo de etiqueta binaria o datos de salida es representado por el estatus de la bomba de inyección (1, aceptada o 0, rechazada). Por otra parte, empleando la biblioteca `neuralnet` en el software R. Se construyó el modelo clasificador de bombas de inyección de combustible como se puede observar en la figura 6. Donde:

- $Estatus \sim ((EC + LAL + ACCG + ACR) - LCB)$: Estatus es la etiqueta binaria del producto y EC, LAL, ACCG, ACR, LCB son dimensiones de componentes.
- *CD*: Es el conjunto de datos de entrenamiento.
- *hidden* = 6: Representa una sola capa con 6 neuronas respectivamente.
- *act.fct* = "logistic": Se usa para suavizar el resultado de la red.
- *linear.output* = FALSE: Da a las redes neuronales la no linealidad.



```
30
31 #Cargando biblioteca o librería
32 require(neuralnet)
33
34 #Creando el Modelo clasificador de Bombas de Inyección
35 Modelo=neuralnet(Estatus~((EC+LAL+ACCG+ACR)-LCB),data=CD,hidden=6,act.fct="logistic",linear.output=FALSE)
36
37
```

Figura 6 Modelo clasificador de bombas de inyección.

Experimentación

Para realizar el trazo de la respectiva red neuronal, es necesaria la ejecución del comando `plot` a través del software R. En la figura 7 se puede observar el esquema trazado. Por otro lado, también se aprecia en la parte inferior de la figura 7 que el error de la red calculada es de 0.000164, lo que significa predicciones más confiables y precisas para la aceptación o rechazo de las bombas de inyección.

Posteriormente, en la figura 8 se desarrolló un conjunto de datos de prueba tomando en cuenta las dimensiones de cuatro bombas nuevas. El propósito es evaluar si serán consideradas bombas aceptadas o rechazadas según los criterios de la red construida.

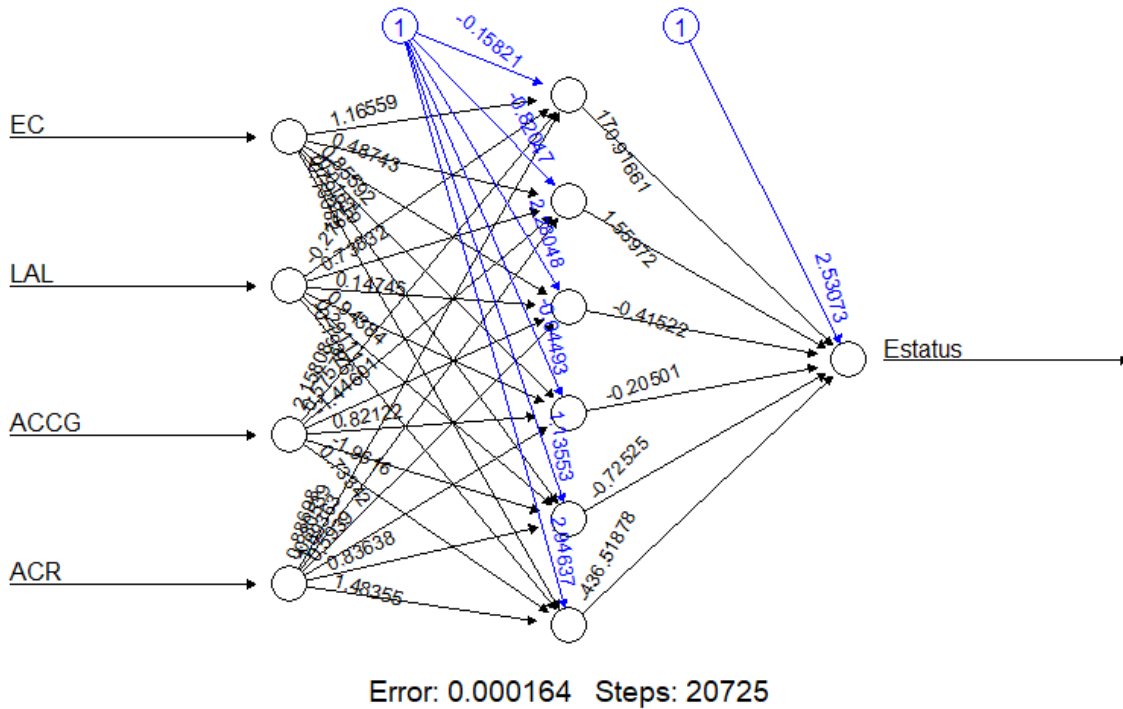


Figura 7 Red neuronal calculada para la optimización de los criterios de aceptación.

```

RedNeuronalShainin.R
Source on Save
Run
Source
40 #Eficiencia de la Red Neuronal
41
42 #Evaluando conjunto de datos de prueba
43
44 #Espesor de la cuña (mm)
45 EC=c(5.79,5.52,5.83,5.55)
46
47 #Longitud del árbol de levas (mm)
48 LAL=c(180.53,180.34,180.16,180.23)
49
50 #Altura del cojinete de la carcasa del gobernador (mm)
51 ACCG=c(14.58,14.41,14.92,14.69)
52
53 #Altura del cojinete de rodamiento (mm)
54 ACR=c(14.19,14.17,14.17,14.16)
55
56 #Longitud de la carcasa de la bomba (mm)
57 LCB=c(214.78,214.79,214.81,214.77)
58
59 #Aquí, combinará múltiples las características a evaluar en un solo conjunto de datos
60 Prueba=data.frame(EC,LAL,ACCG,ACR,LCB)
61
35:105 (Top Level) R Script
    
```

Figura 8 Creación del conjunto de datos de prueba.

Predicción de resultados

En esta etapa se llevó a cabo la predicción de las puntuaciones de probabilidades para los datos de prueba. Los datos mostrados en la figura 9 corresponden a las cuatro bombas nuevas usando el comando compute a través del software R.

```
> #Predecir resultados para el conjunto de prueba usando la Red Neuronal
> Predecir=compute(Modelo,Prueba)
> Predecir$net.result
      [,1]
[1,] 9.966468e-01
[2,] 8.120575e-07
[3,] 9.991992e-01
[4,] 9.653886e-03
```

Figura 9 Predicción de probabilidades en base a datos de prueba.

Después, se convirtieron las puntuaciones de probabilidades en clases binarias estableciendo un nivel de umbral de 0.5. De esta manera se logra la optimización de los criterios de aceptación de las bombas de inyección. Es decir, si la probabilidad resultante se encuentra por encima del nivel de umbral de 0.5, la bomba es clasificada con un 1 (buena o aceptada). Pero, si la probabilidad resultante es menor a 0.5, la bomba es clasificada con un 0 (mala o rechazada), ver figura 10.

Los resultados predichos y observados en la figura 10 son: bomba aceptada (1), bomba rechazada (0), bomba aceptada (1), bomba rechazada (0). Con lo cual se comprueba la efectividad y predicción de la red neuronal creada.

```
> #Conversión de probabilidades en clases binarias estableciendo un nivel umbral 0.5
> prob <- Predecir$net.result
> pred <- ifelse(prob>0.5,1,0)
> pred
      [,1]
[1,]     1
[2,]     0
[3,]     1
[4,]     0
> |
```

Figura 10 Resultados predictivos de la red neuronal.

4. Discusión

Actualmente existen pocos trabajos de investigación sobre el uso de redes neuronales en conjunto con metodologías de resolución de problemas con el fin de optimizar criterios de aceptación de productos a través de la predicción de resultados. Debido a esto, resulta un tema que se puede seguir evaluando y experimentando para validar su efectividad en controles de calidad.

Los resultados son prometedores porque se muestra que las redes neuronales pueden ser utilizadas para este fin de manera efectiva. En este momento la investigación se limita solamente a la interacción de la red neuronal con un caso de

estudio sobre un problema crónico de calidad. Pero el complementar este estudio con otros trabajos que sigan esta misma rama de investigación puede generar resultados innovadores para el futuro de la calidad en las industrias.

5. Conclusiones

Con la utilización de la metodología Shainin y de las redes neuronales artificiales, se concluye que a través de una red neuronal se logró relacionar las variables que influyen en la causa raíz de un problema de calidad con las salidas esperadas de la red sobre la predicción del rechazo o aceptación de un producto. Se destaca la capacidad de las redes para modelar sistemas complejos y obtener menores errores tanto en el entrenamiento como en la predicción.

El resultado obtenido en la presente investigación al utilizar en conjunto metodologías de resolución de problemas y redes neuronales, significa una contribución útil para la calidad de los productos. Se podría convertir en una herramienta rentable para optimizar los criterios de aceptación y reducir el rechazo de productos.

6. Bibliografía y Referencias

- [1] Bhote, K. R., & Bhote, A. K. (2000). *World Class Quality*. New York: American Management Association.
- [2] Flórez, R., & Fernández, J. M. (2008). *Las Redes Neuronales Artificiales Fundamentos teóricos y aplicaciones prácticas*. España: Netbiblo.
- [3] Gelman, L., & Ao, S.-I. (2009). *Advances in Electrical Engineering and Computational Science*. Estados Unidos Americanos: Springer Science & Business.
- [4] González, Ó. C., & Arciniegas, J. A. (2016). *Sistema de gestión de calidad: Teoría y práctica bajo la norma ISO*. Bogotá, Colombia: Ediciones ECOE.
- [5] Gutiérrez, H. (2010). *Calidad Total y Productividad*. México: McGraw-Hill Educación.
- [6] Gutiérrez, H., & De la Vara, R. (2009). *Control Estadístico de Calidad y Seis Sigma*. México: McGraw-Hill.

- [7] González, G. (2016). Motores lineales de imanes permanentes: Principios de funcionamiento y optimización. Colombia: Universidad Autónoma de Occidente.
- [8] Haykin, S. (2009). *Neural Networks and Learning Machines*. New Jersey: Pearson.
- [9] Lahoz-Beltrá, R. (2010). *Bioinformática: Simulación, vida artificial e inteligencia artificial*. Madrid: Ediciones Díaz de Santos.
- [10] Luceño, A., & González, F. J. (2015). *Métodos estadísticos para medir, describir y controlar la variabilidad*. Santander, España: Editorial Universidad de Cantabria.
- [11] Navlani, A. (18 de Enero de 2019). *Neural Network Models in R*. Obtenido de DataCamp Community: <https://www.datacamp.com/community/tutorials/neural-network-models-r>.
- [12] Rey, F. (2003). *Técnicas de Resolución de Problemas: Criterios a seguir en la Producción y el Mantenimiento*. España: FC Editorial.
- [13] Sánchez, F. (2019). *Calidad Total en las Organizaciones*. España: Editorial Elearning S.L.
- [14] Shivdarshan, S., & Jaychandran, K. (2018). Root Cause Detection for Excess Control Rod Vibration in Fuel. *International Journal of Engineering & Technology*, 7(3.6), 364-367.
- [15] Steiner, S. H., MacKay, R. J., & Ramberg, J. S. (2008). An Overview of the Shainin System for Quality Improvement. *Quality Engineering*, 20(1), 6-19. doi:10.1080/08982110701648125
- [16] Valero, S., & Senabre, C. (2013). *Aplicación de un modelo de red neuronal no supervisado a la clasificación de consumidores eléctricos*. España: Editorial Club Universitario.
- [17] Vilar, J. F., & Delgado, T. (2005). *Control Estadístico de los Procesos (SPC)*. Madrid, España: FC Editorial.
- [18] Zapata, A., Sarache, W. A., & Becerra, F. (2012). *Gestión de la Calidad Hacia un modelo integrado de estándares*. Colombia: Universidad Nacional de Colombia.