

DESARROLLO DE UN MODELO DE UN GRÁFICO DE CONTROL MTEWMA MEDIANTE INTELIGENCIA ARTIFICIAL

DEVELOPMENT OF A MTEWMA CONTROL CHART MODEL USING ARTIFICIAL INTELLIGENCE

Jandry Delgado Godoy

Tecnológico Nacional de México / IT de Celaya, México
M2203022@itcelaya.edu.mx

José Antonio Vázquez López

Tecnológico Nacional de México / IT de Celaya, México
antonio.vazquez@itcelaya.edu.mx

José Alfredo Jiménez García

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

Recepción: 22/mayo/2023

Aceptación: 26/octubre/2023

Resumen

En la actualidad, es fundamental que las empresas supervisen y controlen la calidad en sus sistemas de producción, teniendo en cuenta todas las características y aspectos relevantes. Esto permitirá garantizar la satisfacción del cliente, mejorar la competitividad en el mercado y mantener un alto nivel de calidad en los productos o servicios ofrecidos. Para garantizar un control adecuado de los sistemas de fabricación, se requiere el uso de técnicas de control estadístico de procesos multivariados. Este artículo presenta un modelo de gráfico de control de Media Móvil Triple Ponderado Exponencialmente (MTEWMA) que utiliza técnicas de inteligencia artificial para monitorear múltiples características de calidad simultáneamente. El procedimiento de monitoreo y control se utilizó para analizar variables de calidad en el proceso de siembra de arroz. Los resultados obtenidos demuestran que el mecanismo detectó e interpretó con éxito pequeñas variaciones y cambios significativos, identificando el origen de la variación generada en el sistema productivo.

Palabras Clave: Control Estadístico de Procesos, Gráficos de Control, MTEWMA, Inteligencia Artificial.

Abstract

Currently, it is essential for companies to supervise and control quality in their production systems, taking into account all relevant characteristics and aspects. This will allow ensuring customer satisfaction, improving competitiveness in the market, and maintaining a high level of quality in the products or services offered. To ensure proper control of manufacturing systems, the use of multivariate statistical process control techniques is required. This article presents an MTEWMA control chart model that uses artificial intelligence techniques to monitor multiple quality characteristics simultaneously. The monitoring and control procedure was used to analyze quality variables in the rice cultivation process. The results obtained demonstrate that the mechanism successfully detected and interpreted small variations and significant changes, identifying the origin of the variation generated in the production system.

Keywords: *Statistical Process Control, Control Charts, MTEWMA, Artificial Intelligence.*

1. Introducción

En el entorno competitivo actual, es esencial mejorar continuamente los servicios y productos producidos para atraer a los clientes. Esto requiere una vigilancia constante de varios procesos mediante herramientas adecuadas y un mantenimiento adecuado del equipo de producción y fabricación. Además, mantener la variabilidad del proceso dentro de un nivel aceptable puede reducir significativamente el riesgo de obtener productos no deseados, como señala [Montgomery, 2020]. La variación del proceso puede ser causada por causas naturales o especiales, conocidas como azar y causas asignables de variación. Sin embargo, en cualquier proceso significativo, la variación se debe atribuir a causas asignables de variación y debe reducirse o eliminarse lo antes posible.

Se han empleado diversas técnicas en el monitoreo estadístico de procesos (MEP) para detectar y notificar al operador acerca de la presencia de causas asignables

de variación. Según [Montgomery, 2020], Walter A. Shewhart desarrolló un esquema de monitoreo moderno que lleva su nombre, el cual permite un control eficiente de grandes cambios sostenidos en los parámetros del proceso. El gráfico de Shewhart utiliza únicamente la información más reciente para determinar el estado del proceso, por lo que se le conoce como un esquema de monitoreo sin memoria. Por su parte, [Roberts, 2000] introdujo los gráficos de suma acumulativa (CUSUM) y promedio móvil ponderado exponencialmente (EWMA) para detectar cambios pequeños y grandes en los parámetros del proceso. Tanto los gráficos CUSUM como EWMA emplean tanto información reciente como antigua para determinar el estado del proceso, de ahí que se les denomine monitoreo con memoria; no obstante, la información antigua recibe un peso menor en comparación con la información más reciente.

Desde entonces, varios investigadores han contribuido en el diseño y mejora de gráficos de control tanto sin memoria como con memoria. Por ejemplo, [Lucas, 1982], [Klein, 1996], [Jones-Famer, Champ, y Rigdon, 2001] han realizado aportes significativos en esta área. Además, [Chen y Chen, 2007] introdujeron el doble EWMA (DEWMA), que es una extensión del gráfico EWMA de [Roberts, 2000], en el que el parámetro de suavizado se utiliza dos veces, como señalan [Shamma y Shamma, 1992].

Para el seguimiento de dos o más variables relacionadas, se recomienda el uso de gráficos de control multivariado. En 1947, Hotelling introdujo un gráfico de control multivariante que utiliza el estadístico x^2 para representar la distancia de Mahalanobis ponderada entre una observación de muestra y el centro de la nube, según [Crosier, 1988]. Alternativamente, [Lowry, Woodall, Champ y Rigdon, 1992] propusieron gráficos de control multivariante CUSUM (MCUSUM) y multivariante EWMA (MEWMA) como alternativas a los gráficos CUSUM y EWMA, respectivamente. Estos gráficos se utilizan para monitorear de manera eficiente cambios de pequeños a moderados en los parámetros del proceso. Recientemente, [Alevizakos, Chatterjee y Koukouvinos, 2021] han ampliado los esquemas EWMA y DEWMA al desarrollar el gráfico de control triple EWMA, en el que el parámetro de suavizado se aplica tres veces. Este trabajo se ha publicado como "A triple

exponentially weighted moving average control chart for monitoring time between events", y representa una importante contribución al campo.

Hay numerosas investigaciones enfocadas en el diseño de gráficos de control que incorporan múltiples variables del proceso y en la reducción del tiempo de alerta fuera de control; esto requiere de procesos complejos en su diseño. Sin embargo, una de las desventajas importantes del análisis multivariado es que sus técnicas son complicadas, involucran matemáticas avanzadas y requieren procedimientos estadísticos para analizar los datos, lo que puede ser costoso y difícil de implementar para algunas personas u organizaciones. A pesar de que la realización de procedimientos estadísticos es sencilla, se necesita de entrenamiento para comprender completamente los datos. Para solucionar el desafío planteado y disminuir la carga de trabajo humano, se ha propuesto el uso de Inteligencia Artificial, en concreto, una Red Neuronal Perceptron, para diseñar gráficos de control, específicamente, se sugiere la utilización de un gráfico de control de media móvil multivariante triple ponderado exponencialmente, el cual se ha desarrollado con la ayuda del software MATLAB.

Breve revisión de las cartas de control EWMA multivariante y doble EWMA

En esta sección se explicará la base matemática y las características esenciales para diseñar los gráficos de control MEWMA y MDEWMA.

Gráfico de control MEWMA

Supongamos que tenemos un vector aleatorio de p -componentes $\mathbf{X} = (x_1, x_2, \dots, x_p)$ que representa p características de calidad aleatorias obtenidas de manera conjunta de un proceso de interés. Si el proceso está en control (IC), asumimos que \mathbf{X} sigue una distribución normal p -variada con un vector de media $\boldsymbol{\mu}_0$ y una matriz de dispersión $\boldsymbol{\Sigma}_0$, es decir, $\mathbf{X} \sim N_p(\boldsymbol{\mu}_0, \boldsymbol{\Sigma}_0)$. Con el tiempo, supongamos que hemos observado $\mathbf{x}_i (i = 1, 2, \dots)$. Por lo tanto, como una extensión natural del gráfico de control EWMA univariado, definimos la ecuación 1.

$$Y_{1i} = \lambda X_i + (1 - \lambda)Y_{1(i-1)} \quad i = 1, 2, \dots, \quad (1)$$

La expresión $\Lambda = \text{diagonal}(\lambda_1, \lambda_2, \dots, \lambda_p)$, $0 < \lambda_j \leq 1, j = 1, 2, \dots, p$ y $y_{10} = u_0$ se refiere a la definición de ciertos parámetros necesarios para el diseño del gráfico de control MEWMA. La matriz Λ se define como una matriz diagonal que contiene los parámetros $\lambda_1, \lambda_2, \dots, \lambda_p$. Estos parámetros son números entre 0 y 1, que se utilizan para ponderar los valores de las variables de calidad. Por otro lado, se define el vector y_{10} como el vector de medias de las variables de calidad cuando el proceso está en control. A partir de esto, la ecuación 1 puede ser simplificada a ecuación 2.

$$Y_{1i} = \Lambda \sum_{k=1}^i (1 - \Lambda)^{1-k} X_k + (1 - \Lambda)^i \mu_0 \quad (2)$$

Cuando el proceso está en control, el vector de media del proceso y la matriz de dispersión de la estadística de control definida en la ecuación 1 están definidos por la ecuación 3.

$$E(Y_{1i}|IC) = u_0 \text{ y } \Sigma_{y_{1i}} = \sum_{k=1}^i G_{1k} \Sigma_0 G'_{1k}, \quad (3)$$

Donde $G_{1k} = \Lambda(I - \Lambda)^{i-k}$.

Por lo tanto, el gráfico MEWMA da una señal de OOC si se cumple la ecuación 4.

$$u_{1i}^2 = (Y_{1i} - \mu_0)' \sum_{y_i}^{-1} (Y_{1i} - \mu_0) \geq hMEWMA \quad (4)$$

Donde $hMEWMA (> 0)$ se elige para lograr un valor especificado de longitud media de corrida (ARL_0) para el proceso en control.

Si no tenemos información previa relacionada con la elección de los pesos de las observaciones de manera diferente para las p características de calidad, entonces asumimos $\lambda_1 = \lambda_2 = \dots = \lambda_p = \lambda$. Bajo esta suposición, el vector de gráficos MEWMA se puede escribir como en la ecuación 5.

$$Y_{1i} = \lambda X_i + (1 - \lambda) Y_{1(i-1)} \quad (5)$$

Basándose en la ecuación 5, el vector de media y la matriz de dispersión variable en el tiempo (es decir, en el caso de estado cero) de la estadística de registro definida en la ecuación 5 se dan por la ecuación 6.

$$\Sigma_{y_{1i}} = (C_{11} + C_{12}(i))\Sigma_0 \quad (6)$$

Donde:

$$C_{11} = \frac{\lambda}{2 - \lambda}$$

$$C_{12}(i) = -\frac{\lambda(1 - \lambda)^{2i}}{2 - \lambda}$$

Cuando el proceso ha estado funcionando durante mucho tiempo (es decir, el caso asintótico también conocido como el caso de estado estacionario), $i \rightarrow \infty$ y $C_{12}(i)$ converge hacia cero de modo que $\Sigma_{y_{1i}} = C_{11}\Sigma_0$.

Gráfico de control MDEWMA

Como una extensión natural del gráfico de control DEWMA univariado, definimos el vector de gráficos de control MDEWMA mediante la ecuación 7.

$$Y_{2i} = \Lambda Y_{1i} + (I - \Lambda)Y_{2(i-1)} \quad (7)$$

Donde Λ y Y_{1i} están definidos en la ecuación 1 y $Y_{20} = u_0$. Sin pérdida de generalidad, se puede demostrar que la ecuación 7 puede simplificarse a la ecuación 8.

$$Y_{2i} = \Lambda^2 \sum_{k=1}^i (i - k + 1)(1 - \Lambda)^{i-k} X_k + (i\Lambda + I)(1 - \Lambda)^i u_0 \quad (8)$$

Cuando el proceso es IC, el vector de media del proceso y la matriz de dispersión de la estadística de gráficos definida en la ecuación 7 se definen por $E(Y_{2i}|IC) = u_0$ y la ecuación 9.

$$\Sigma_{y_{2i}} = \sum_{k=1}^i (i - k + 1)^2 G_{2k} \Sigma_0 G_{2k}' \quad (9)$$

Donde $G_{2k} = \Lambda^2(I - \Lambda)^{i-k}$. Por lo tanto, la gráfica de control MDEWMA muestra una señal fuera de control la cual se muestra mediante la ecuación 10.

$$u_{2i}^2 = (Y_{2i} - \mu_0)' \sum_{y_{2i}}^{-1} (Y_{2i} - \mu_0) \geq hMDEWMA \quad (10)$$

Donde $hMDEWMA (> 0)$ se elige para lograr un valor especificado de ARL_0 .

Cuando $\lambda_1 = \lambda_2, = \dots = \lambda_p = \lambda$, bajo esta suposición, el vector de control MDEWMA se puede escribir como muestra la ecuación 11.

$$Y_{2i} = \lambda_1 Y_{1i} + (1 - \lambda) Y_{2(i-1)} \quad (11)$$

Basándonos en la ecuación 11, el vector de media y la matriz de dispersión variable en el tiempo de la estadística de control definida en la ecuación 9 son los que se muestra mediante la ecuación 12.

$$\Sigma_{y_{2i}} = (C_{21} + C_{22}(i)) \Sigma_0 \quad (12)$$

Donde:

$$c_{21} = \lambda^4 \left[\frac{2\theta}{(1-\theta)^3} + \frac{1}{(1-\theta)^2} \right]$$

$$c_{22}(i) = -\lambda^4 \left[\frac{(1+i)^2 \theta^2}{(1-\theta)} + \frac{(2i+3)\theta^{i+1}}{(1-\theta)^2} + \frac{2\theta^{i+2}}{(1-\theta)^3} \right]$$

$$\theta = (1 - \lambda)^2$$

Cuando el proceso ha estado funcionando durante mucho tiempo, $i \rightarrow \infty$ y $C_{22}(i)$ converge hacia cero de modo que $\Sigma_{y_{2i}} = C_{21} \Sigma_0$.

Gráfico de control MTEWMA

Más recientemente, [Alevizakos, Chatterjee, & C, 2021] introdujeron el esquema univariado TEWMA para monitorear una característica de calidad para observaciones normalmente distribuidas. Como una extensión natural del gráfico de control univariado TEWMA, definimos además de las ecuaciones 1 y 7 la siguiente estadística MTEWMA, la cual sería la ecuación 13.

$$Y_{3i} = \Lambda Y_{2i} + (I - \Lambda) Y_{3(i-1)} \quad (13)$$

Donde Λ y Y_{2i} están definidos en las ecuaciones 1 y 7, respectivamente y $Y_{30} = u_0$. Sin pérdida de generalidad, se puede demostrar que la ecuación 13 se puede simplificar a la ecuación 14.

$$Y_{2i} = \frac{\Lambda^3}{2} \sum_{k=1}^i (i-k+1)(i-k+2)(1-\Lambda)^{i-k} X_k + \frac{1}{2} (i(i+1)\Lambda^2 + 2i\Lambda + 2I)(1-\Lambda)^i u_0 \quad (14)$$

Cuando el proceso está en control estadístico, el vector de media del proceso y la matriz de dispersión de la estadística de control definida en la ecuación 13 se definen por la ecuación 15. Donde $G_{2k} = \frac{\lambda^3}{2} (I - \lambda)^{i-k}$.

$$\Sigma_{y_{3i}} = \sum_{k=1}^i (1-k+1)^2 (1-k+2)^2 G_{2k} \Sigma_0 G'_{2k} \quad (15)$$

Por lo tanto, el gráfico MTEWMA da una señal OOC si se cumple la ecuación 16.

$$u_{3i}^2 = (Y_{3i} - \mu_0)' \Sigma_{Y_{3i}}^{-1} (Y_{3i} - \mu_0) \geq h_{MTEWMA} \quad (16)$$

Donde $h_{MTEWMA}(>0)$ se elige para lograr un valor especificado de ARL_0 .

Cuando $\lambda_1 = \lambda_2, = \dots = \lambda_p = \lambda$, bajo esta suposición, el vector de control MTEWMA se puede escribir como la ecuación 17

$$Y_{3i} = \lambda Y_{2i} + (1 - \lambda) Y_{3(i-1)} \quad (17)$$

Basándonos en la ecuación 17, el vector de media y la matriz de dispersión que varía con el tiempo de la estadística de control definida en la ecuación 15 se convierten en la ecuación 18.

$$\Sigma_{y_{3i}} = (C_{31} + C_{32}(i)) \Sigma_0 \quad (18)$$

Donde:

$$c_{31} = \frac{6(1-\lambda)^6 \lambda}{(2-\lambda)^5} + \frac{12(1-\lambda)^4 \lambda^2}{(2-\lambda)^4} + \frac{7(1-\lambda)^2 \lambda^3}{(2-\lambda)^3} + \frac{\lambda^4}{(2-\lambda)^2}$$

$$c_{32}(i) = -\frac{\theta^3 \lambda^6}{4} \left[\frac{i(i^2-1)(i-2)\theta^{i-3}}{(1-\theta)} + \frac{4i(i^2-1)\theta^{i-2}}{(1-\theta)^2} + \frac{12i(i+1)\theta^{i-1}}{(1-\theta)^3} + \frac{24(i+1)\theta^i}{(1-\theta)^4} \right.$$

$$\left. + \frac{24\theta^{i+1}}{(1-\theta)^5} \right] - 2\theta \lambda^6 \left[\frac{i(i^2-1)\theta^{i-2}}{(1-\theta)} + \frac{3(i+1)\theta^{i-1}}{(1-\theta)^2} + \frac{6(i+1)\theta^i}{(1-\theta)^3} + \frac{6\theta^{i+1}}{(1-\theta)^4} \right]$$

$$- \frac{7\theta \lambda^6}{2} \left[\frac{i(i+1)\theta^{i-1}}{(1-\theta)} + \frac{2(i+1)\theta^i}{(1-\theta)^2} + \frac{2\theta^{i+1}}{(1-\theta)^3} \right] - \lambda^6 \left[\frac{\theta^{i+1}}{(1-\theta)^2} + \frac{(i+1)\theta^i}{(1-\theta)} \right]$$

θ está definido en la ecuación 12. Cuando el proceso ha estado en funcionamiento durante mucho tiempo $i \rightarrow \infty$ y $C_{31}(i)$ converge hacia cero de manera que $\Sigma_{y_{3i}} = C_{31} \Sigma_0$. Tenga en cuenta que cuando $n > 1$, en lugar de Y_{1i} , Y_{2i} y Y_{3i} , se utilizan sus respectivos vectores de media y sus matrices de dispersión correspondientes se dividen por n .

Estudios previos Inteligencia Artificial en Gráficos de Control

Se han realizado investigaciones que combinan el control estadístico y las redes neuronales artificiales, como el trabajo realizado por [Chiñas, López, y Vázquez, 2013]. Este método utiliza la estadística T^2 Hotelling y MEWMA para el reconocimiento de variables mediante las RNA.

El estudio también se enfoca en la aplicación de una red neuronal artificial para detectar puntos fuera de los límites de control y patrones provocados por causas especiales, a través de la clasificación de datos obtenidos del gráfico MTEWMA. Se espera que este enfoque permita tomar medidas correctivas.

Es importante tener en cuenta, la capacidad de la RNA para adaptarse a cambios en la información de entrada [Ruelas, 2017]. Por lo tanto, se recomienda utilizar el gráfico MTEWMA junto con alguna técnica de análisis de señales fuera de control para obtener una interpretación más precisa de los resultados.

2. Métodos

El método de trabajo propuesto para el consta de los siguientes pasos:

- **Recopilación de Datos:** En esta etapa, se recopilarán los datos necesarios para el estudio. Se utilizarán fuentes confiables y relevantes para garantizar la calidad de los datos recopilados.
- **Análisis Estadístico del Comportamiento de las Variables:** Una vez obtenidos los datos, se realizará un análisis estadístico exhaustivo de las variables involucradas. Se aplicarán técnicas estadísticas para comprender su comportamiento, identificar patrones y detectar posibles anomalías.
- **Determinación del Control Estadístico:** A partir del análisis estadístico previo, se fijarán los límites de control para el Gráfico de Control MTEWMA, facilitando la supervisión y gestión de las variables con umbrales de alerta y acción definidos.
- **Implementación de Inteligencia Artificial (IA):** En esta etapa, se emplearán técnicas de IA, incluyendo algoritmos de aprendizaje automático, para potenciar la capacidad predictiva y de detección de anomalías del modelo. La IA facilitará la identificación de patrones no visibles a simple vista y ajustes

dinámicos basados en la información recopilada. Consultar figura 1 para una representación visual del enfoque de investigación.

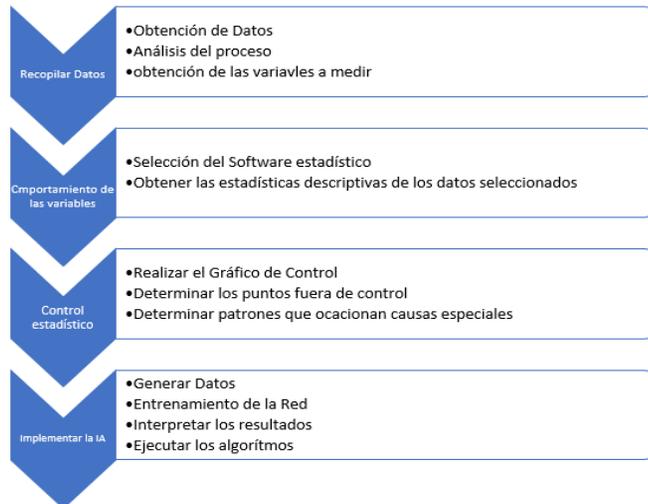


Figura 1 Metodología de la Investigación.

Caso de estudio. Siembra de arroz en la India

En el presente estudio se realizó una exhaustiva recolección de datos utilizando una base disponible en [Kaggle Inc, 2023].

Dicha base de datos contiene mediciones de pH, temperatura y humedad en suelos de la India donde se sembró arroz en diferentes meses del pasado, con cada registro presentando una cabecera de datos que incluye estas variables. Esto proporciona una estructura clara y fácil de interpretar para el análisis de los datos.

Se tomó especial cuidado en la selección de la base de datos, eligiendo únicamente aquella que era confiable y relevante para el estudio. Además, se aseguró que los registros de mediciones correspondían a suelos donde la calidad del arroz era excepcionalmente buena, garantizando así la alta calidad de los datos recopilados y reflejando condiciones óptimas para el cultivo de arroz en la India. Se consideró que los valores óptimos para el cultivo de arroz en suelos de la India son un pH de 6 a 7.5, una temperatura de 20 a 35 °C y una humedad del 70 al 90%, según lo identificado por [Fiestas Trujillo & Puga Coronado, 2018]. Es importante tener en cuenta que estos valores pueden variar en función de otros factores ambientales y del tipo de suelo en el que se cultiva. Después, se explica detalladamente los pasos

y los objetivos a tener en cuenta en el entrenamiento de una red neuronal artificial, para detectar puntos fuera de control y causas especiales.

3. Resultados

Se empleó la prueba de normalidad de Shapiro-Wilk para verificar la normalidad de los datos en las tres variables principales. Los resultados de esta prueba indicaron que tres variables tienen una distribución normal. La figura 2 muestra los resultados de estas pruebas.

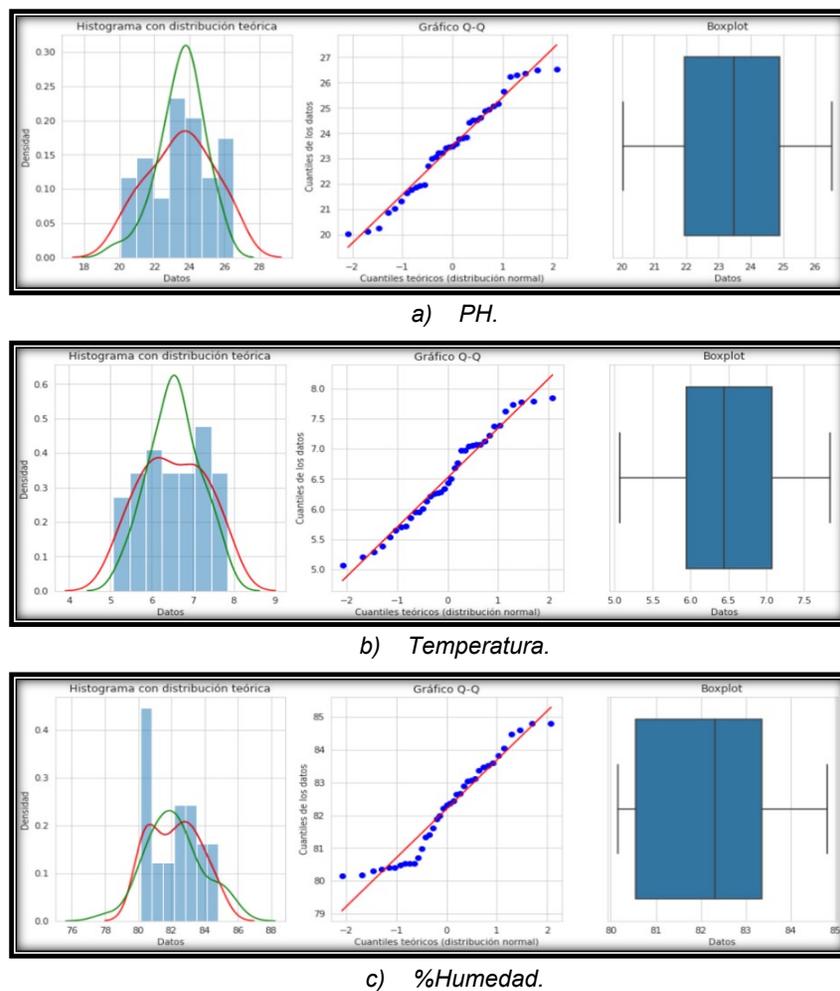


Figura 2 Pruebas de normalidad de las tres variables.

Es fundamental tener en cuenta que la distribución normal de los datos es un requisito esencial para la aplicación de diversas técnicas estadísticas y modelos

matemáticos. Por lo tanto, es necesario tomar precaución al trabajar con variables que no cumplen con este supuesto.

Estado de control estadístico del proceso

Para determinar el estado de control estadístico del proceso es esencial crear gráficas y analizar los patrones presentes en ellas. Este análisis permite identificar las causas asignables y determinar si el proceso se encuentra dentro del estado de control estadístico. Se empleó la información inicial para generar un gráfico de control MTEWMA que considera las tres variables de estudio, figura 3.



Figura 3 Gráfico de Control MTEWMA.

Para calcular el estadístico MTEWMA se seleccionaron aleatoriamente 30 muestras (justificar por que 30) de nuestra base de datos, utilizando las fórmulas correspondientes que se detallan en la introducción.

No se ha observado ningún punto fuera de los límites de control en este caso. El límite de control se calcula utilizando las tablas proporcionadas por [Alevizakos, Chatterjee, & Koukouvinos, 2021] con un ARL de 200, un valor $p = 3$ y un tamaño de muestra $n = 1$, lo que resultó en un límite de control de 6.483.

Generación de Datos

En el proceso de entrenamiento de la red neuronal, es fundamental considerar la mayor cantidad posible de escenarios en los datos para lograr una efectividad óptima. Para este propósito, se realizó una simulación Monte Carlo con el objetivo de crear una base de datos que permita el entrenamiento de la red. En esta base

de datos se asignó un valor de 1 a los puntos que se encuentran dentro de los límites de control y un valor de 0 a los que están fuera de los límites. Se utilizó esta topología para abarcar todo punto que podrían encontrarse en el gráfico, figura 4.

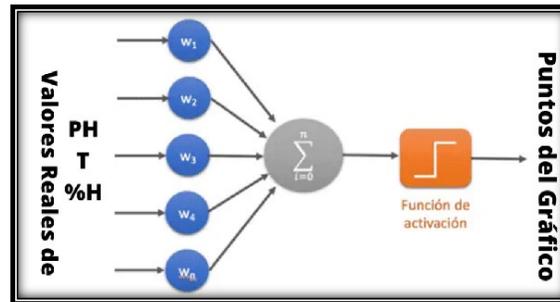


Figura 4 Diseño de la Red.

La variable de respuesta principal será la precisión del modelo de clasificación. De acuerdo con [Ruelas Santoyo & Cruz Salgado , 2020], el éxito del proceso de clasificación se puede probar con base en el índice de precisión, el cual se describe mediante la ecuación 19.

$$Exactitud = \frac{\text{Eventos con una clasificación correcta}}{\text{Pruebas realizadas}} * 100 \quad (19)$$

Después de llevar a cabo un experimento para obtener los parámetros óptimos, se ha llegado a la conclusión de que los valores mostrados en la tabla 1 son los adecuados.

Tabla 1 Parámetros operativos de la Red.

Parámetro	Valor
Función de activación	Tangente – Sigmoidea
Tipo de entrenamiento	Gradiente conjugado
Neuronas en la capa oculta	3
Gradiente	2.08e-08
Tasa de aprendizaje	1
Error permitido	1.00e-10
Iteraciones	41

El perceptrón de tres neuronas en la capa oculta ha demostrado ser eficiente y capaz de identificar patrones en los datos en la red neuronal desarrollada. A pesar de su estructura simple, los resultados obtenidos son interpretables de manera

intuitiva y la red puede generalizar correctamente en datos que no fueron parte del entrenamiento. No obstante, es importante considerar que esta red (Figura 5) puede enfrentar dificultades al tratar con conjuntos de datos complejos o altamente no lineales. Por lo tanto, antes de determinar si esta estructura de red es la más adecuada, es necesario evaluar la complejidad de los datos y la naturaleza del problema en cuestión. En algunos casos, puede ser necesario aumentar la complejidad de la arquitectura de la red para obtener resultados óptimos.

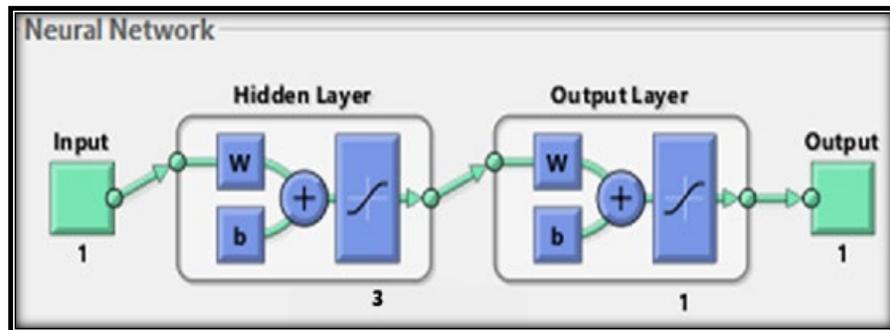


Figura 5 Estructura de la Red.

4. Discusión

Para validar la utilidad de la red neuronal artificial en la tarea de clasificación y determinar la naturaleza de la variabilidad en, se llevó a cabo una fase de prueba, obteniendo la tabla 2 como conclusión.

Tabla 2 Exactitud en la tarea de Clasificación.

Escenario	% de Exactitud	Aciertos	Errores
Escenario 1	0.99	99	1
Escenario 2	1	100	0
Escenario 3	1	100	0
Escenario 4	0.99	99	1
Escenario 5	1	100	0
\bar{X}	0.996	498	2

Según el estudio llevado a cabo, se puede comprobar que la red neuronal artificial (RNA) perceptrón multicapa resulta ser una herramienta altamente eficaz para llevar a cabo la tarea de clasificación y detección de la variabilidad en sistemas productivos. Es importante destacar que la metodología presentada es altamente

flexible, ya que puede ser utilizada en procesos donde se busca identificar cambios sutiles (1σ y 2σ), ya que se encuentran bajo control estadístico, así como también brinda excelentes resultados para evaluar procesos con variaciones más significativas (3σ).

5. Conclusiones

La automatización en los sistemas productivos actuales ha aumentado significativamente, por lo que es importante contar con mecanismos que permitan un control efectivo de la calidad del producto. Para ello, se propone un procedimiento de control multivariante que combina esquemas de control MTEWMA y sensores de RNA multicapa para hacer un seguimiento cercano de las características de calidad más importantes presentes en los productos, incluso con grandes volúmenes de producción.

Los resultados muestran que la metodología propuesta, que utiliza técnicas de Perceptrón, tiene una eficiencia del 99.6 % en la tarea de reconocimiento de puntos estadísticos al analizar grandes cantidades de datos.

Aunque no se comparó con otras redes, como Fuzzy ARTMAP o Support Vector Machines (SVM), se sugiere que estas técnicas se consideren en investigaciones futuras debido a su mayor flexibilidad en la clasificación y entrenamiento más rápido. Además, se propone incluir la detección de patrones por estas redes, ya que son importantes para analizar los gráficos de control y detectar las causas asignables de la variación del proceso.

El procedimiento propuesto permite a las empresas establecer y caracterizar la fuente de variación en sus procesos de forma confiable, lo que les permite realizar ajustes pertinentes en sus procesos de manera oportuna para garantizar la productividad, calidad del producto y satisfacción del cliente.

6. Bibliografía y Referencias

- [1] V. Alevizakos, K. Chatterjee y K. C, «A triple exponentially weighted moving average control chart for monitoring time between events., » *Quality and Reliability Engineering International*, vol. 37, nº 3, pp. 1059-1079, 2021.

- [2] D. Montgomery, *Introduction to Statical Quality Control*, Octava ed., J. W. & Sons, Ed., 2020.
- [3] H. Hotteling, «Multivariate quality control illustrated by the air testing of sample bombsights, » de *Techniques of Statistical Analysis*, Eisenhart MWHC, Wallis WA, 1947, pp. 111-184.
- [4] A. Chen y Y. Chen, «Design of EWMA and CUSUM control charts subject to random shift sizes and quality impacts, » *IIE Transactions*, vol. 39, n° 12, pp. 1127-1141, 2007.
- [5] C. Lowry, W. Woodall, C. Champ y S. Rigdon, «A multivariate exponentially weighted moving average control chart, » *Technometrics*, vol. 34, n° 1, pp. 46-53, 1992.
- [6] S. Roberts, «Control chart tests based on geometric moving averages, » *Technometrics*, vol. 42, n° 1, pp. 97-101, 2000.
- [7] J. Lucas, «Combined Shewhart-CUSUM quality control schemes, » *Journal of Quality Technology*, vol. 14, n° 2, pp. 51-59, 1982.
- [8] M. Klein, «Composite Shewhart-EWMA statistical control schemes, » *IIE Transactions*, vol. 28, n° 6, pp. 475-481, 1996.
- [9] L. Jones-Famer, C. Champ y S. Rigdon, «The performance of exponentially weighted moving average charts with estimated parameters, » *Technometrics*, pp. 156-167, 2001.
- [10] R. B. Crosier, «Multivariate generalizations of cumulative sum quality-control schemes, » *Technometrics*, vol. 30, n° 3, pp. 291-303, 1988.
- [11] Kaggle Inc. Kaggle: <https://www.kaggle.com/>.
- [12] Fiestas trujillo, J. L., & Puga Coronado, P.«Desarrollo de un sistema de monitoreo de temperatura ambiental y nivel de PH con control de humedad relativa del suelo y nivel de iluminación basado en PWM, orientado al estudio del cultivo de plantas.» , 2018.