

MONITOREO E INTERPRETACIÓN DE LA VARIACIÓN GENERADA EN PROCESOS MULTIVARIADOS A PARTIR DE LA INTEGRACIÓN DEL GRAFICO DE CONTROL MCUSUM Y RED NEURONAL PERCEPTRON MULTICAPA

MONITORING AND INTERPRETATION OF THE VARIATION GENERATED IN MULTIVARIATE PROCESSES FROM THE INTEGRATION OF MCUSUM CONTROL CHART AND MULTILAYER PERCEPTRON NEURAL NETWORK

Alejandro Franco Tello

Tecnológico Nacional de México / IT de Celaya, México
M2403016@itcelaya.edu.mx

Edgar Augusto Ruelas Santoyo

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

Vicente Figueroa Fernández

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

Manuel Darío Hernández Ripalda

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

Yaquelin Verenice Pantoja Pacheco

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

Claudia Iveth Cancino de la Fuente

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

Recepción: 26/mayo/2025

Aceptación: 5/octubre/2025

Resumen

La variabilidad que se encuentra dentro de los procesos de fabricación origina muchos de los problemas de calidad que sufren las organizaciones manufactureras. En el caso de no ser monitoreada correctamente, aumenta las probabilidades de producir productos de baja calidad y, por consecuencia, aumentan los costos de

producción. El objetivo del control estadístico de la calidad es poder detectar rápidamente la ocurrencia de causas asignables de variación en el proceso de fabricación e investigar las causas que la han generado para reducirlas o eliminarlas. En el artículo se presenta el desarrollo de una metodología que integra el grafico de control MCUSUM y la red neuronal artificial perceptrón multicapa para la detección e interpretación de las fuentes de variación que se generan en los sistemas productivos. De esta manera, la metodología permitirá localizar la(s) variable(s) que causa(n) el descontrol en el proceso, logrando emprender acciones correctivas que consigan reducirlas o eliminarlas en la fabricación de productos fuera de especificación de forma oportuna. La metodología propuesta fue implementada en un proceso de fabricación de placas de circuito impreso y se logra clasificar el origen de la variación generada en el sistema productivo con una exactitud promedio del 96.71%.

Palabras clave: red neuronal artificial, gráfico de control multivariado, control estadístico multivariado de procesos.

Palabras Clave: Control estadístico multivariado, MCUSUM, Red neuronal artificial.

Abstract

The variability found within manufacturing processes causes many of the quality problems experienced by manufacturing organizations. If not properly monitored, it increases the probability of producing low quality products and, consequently, increases production costs. The objective of statistical quality control is to be able to quickly detect the occurrence of assignable causes of variation in the manufacturing process and to investigate the causes that have generated it in order to reduce or eliminate them. This article presents the development of a methodology that integrates the MCUSUM control chart and the multilayer perceptron artificial neural network for the detection and interpretation of the sources of variation generated in production systems. In this way, the methodology will allow locating the variable(s) that cause(s) the lack of control in the process, being able to take corrective actions to reduce or eliminate them in the manufacture of products out of specification in a timely manner. The proposed methodology was implemented in a printed circuit

board manufacturing process and it was possible to classify the origin of the variation generated in the production system with an average accuracy of 96.71%.

Keywords: *Artificial neural network, Multivariate statistical control, MCUSUM.*

1. Introducción

El éxito de una empresa depende en gran medida de la calidad y productividad de los bienes o servicios que ofrece. En este sentido, la calidad se ha consolidado como un factor estratégico fundamental para el crecimiento sostenible y la permanencia competitiva en el mercado [Lokuge, 2025].

Históricamente, la industria ha manifestado un interés constante por el control y la mejora de la calidad. Este interés está estrechamente relacionado con la comprensión de la interdependencia entre calidad y productividad, así como con el reconocimiento del papel crucial que desempeñan estos factores en el fortalecimiento de la competitividad empresarial, independientemente del sector económico [Xu, 2025]. Entre los diversos enfoques del control de calidad, destaca la aplicación del método científico como herramienta fundamental para obtener de manera más eficiente información relevante generada durante el proceso productivo. Esta información es esencial para tomar decisiones orientadas a minimizar la variabilidad del proceso. En este contexto, la estadística ofrece una metodología robusta para la recolección, análisis e interpretación de datos, lo que permite evaluar el comportamiento del proceso y determinar su estado en cualquier etapa de la producción [Chen, 2023]. El Control Estadístico de Procesos (CEP) hace referencia al uso de herramientas estadísticas que permiten evaluar la calidad de un proceso productivo. A partir de los datos obtenidos, es posible contrastarlos con los requerimientos del cliente y, en función de ello, aplicar acciones correctivas orientadas a la mejora continua, siendo la reducción de la variabilidad uno de los principales objetivos de este enfoque [Oakland, 2007].

En todo proceso de fabricación existe una variabilidad inherente. Por ello, se asume que las características consideradas como indicadores medibles de la calidad de un producto o servicio están sujetas a cierto grado de variación. Dado que esta variabilidad no es deseada, uno de los principales objetivos del control de calidad

es analizarla para reducirla o, al menos, mantenerla dentro de los límites establecidos por las especificaciones [Monaco, 2025]. Tal como se indicó previamente, en los procesos de fabricación siempre existe cierta variabilidad, la cual puede atribuirse a causas especiales. No obstante, cuando un proceso se encuentra en estado de control, significa que dicha variabilidad se debe únicamente a causas comunes o aleatorias, propias del sistema [Richter, 2022]. Hoy en día, el Control Estadístico de Procesos (CEP) cuenta con diversas técnicas ampliamente empleadas para la supervisión de los procesos de producción. Su finalidad principal es controlar aquellas características críticas de calidad del producto mientras se encuentra en fabricación. Estas herramientas permiten identificar la presencia de causas especiales de variación, las cuales no forman parte constante del proceso, pero pueden aparecer como resultado de situaciones específicas y atribuibles [Dutoit, 2019]. En la mayoría de los procesos productivos, el monitoreo se realiza a través de cartas de control, las cuales proporcionan una representación gráfica del comportamiento del proceso. Estas cartas muestran los valores de las variables estadísticas que se deben vigilar, aplicados a una secuencia de muestras tomadas de manera continua [Calabrò, 2025].

El monitoreo de procesos implica la medición y control de múltiples características de calidad que pueden estar interrelacionadas. Si estas correlaciones no se consideran y se emplean únicamente cartas de control univariados para supervisar la estabilidad del proceso en cada variable por separado, puede producirse una pérdida significativa de información. En este contexto, el Control Estadístico Multivariado de Procesos (CEMP) representa una alternativa más eficaz frente al enfoque univariado [De Lima, 2014].

En los procesos de producción modernos, es común que ciertas características influyan de manera conjunta y estén interrelacionadas, afectando directamente la calidad final del producto. Por esta razón, resulta esencial supervisarlas simultáneamente a través de métodos de control multivariado. Este enfoque no solo permite evaluar el impacto individual de cada característica sobre la calidad, sino también considerar los efectos derivados de sus interacciones [De Almeida Moreira, 2021].

Hoy en día, el gráfico T^2 de Hotelling es una herramienta consolidada en el control de calidad, ampliamente estudiada y utilizada para supervisar múltiples variables de calidad correlacionadas dentro de un proceso productivo. Sin embargo, cuando se requiere detectar cambios pequeños —del orden de una desviación estándar o menos— con mayor sensibilidad en el vector de medias, se ha propuesto el uso de gráficos de control multivariantes basados en sumas acumuladas (MCUSUM) como una alternativa más eficaz [Miekley, 2013]. Los gráficos de control hacen uso de datos recopilados directamente del proceso, lo que mejora su habilidad para identificar señales que indican un posible estado fuera de control. A diferencia del gráfico T^2 de Hotelling, los gráficos MCUSUM integran un enfoque acumulativo, donde cada punto representado incluye información no solo del instante actual, sino también de observaciones previas, lo que incrementa su capacidad para detectar cambios sutiles en el proceso a lo largo del tiempo [Ahsan, 2022]. El gráfico de control MCUSUM representa una evolución multivariada del gráfico de suma acumulada (CUSUM), orientado a incrementar la sensibilidad frente a variaciones leves del proceso, superando así al gráfico T^2 . Este enfoque se sustenta en acumular información proveniente de observaciones anteriores. En su estructura, cada periodo recibe igual peso en el cálculo estadístico, lo cual le otorga una destacada capacidad para identificar alteraciones mínimas surgidas durante la producción [Dittrich, 2022]. Es importante señalar que uno de los inconvenientes de los gráficos de control estadístico multivariado radica en la falta de un mecanismo específico que permita determinar cuál o cuáles variables son responsables de generar la señal fuera de control en el gráfico [Aguado, 2007]. La dificultad para interpretar las señales de advertencia emitidas por los gráficos de control multivariantes puede ocasionar un uso ineficiente del tiempo y los recursos destinados a identificar la causa de variación en el sistema productivo, lo cual repercute negativamente en la calidad del producto y en la competitividad de la empresa [Melanie, 2015]. Uno de los objetivos más importantes y de suma importancia en el control estadístico de procesos es detectar de manera más rápida cualquier anomalía o cambio dentro del proceso y por consecuencia, poder tomar acciones para reducir la variabilidad del proceso .

Para facilitar la interpretación de señales fuera de control dentro de los gráficos de control multivariantes donde existen diferentes propuestas en la literatura de las cuales destacan diferentes técnicas que complementan el uso de los gráficos de control multivariante [Anojahatlo, 2022]. Dentro de la investigación que fue desarrollada por parte de Bays et al [Bays, 2023], se establece que una herramienta que emplea redes neuronales artificiales para identificar y reconocer un descontrol en el proceso de manufactura. Continuando con el uso de redes neuronales artificiales empleadas en el monitoreo de la calidad en los sistemas productivos, Yao et al [Yao, 2022]. En su trabajo se plantea la aplicación de gráficos de control multivariados para aislar patrones anómalos en el funcionamiento de enfriadoras centrífugas, permitiendo posteriormente identificar fallas específicas mediante un algoritmo de clasificación basado en técnicas como árboles de decisión y bosques aleatorios, logrando una precisión diagnóstica del 82.3%. En el trabajo de Hoga Y. [Hoga, 2017]. Se propone un enfoque de monitoreo de procesos que combina el análisis de componentes principales, algoritmos genéricos y cartas de control univariados como suma acumulada (CUSUM) y de promedio móvil exponencial. Esta integración permite reducir la incidencia de falsas alarmas y, al mismo tiempo, aumentar la capacidad para detectar fallas dentro del proceso de manera más eficaz. En la investigación de Hu et al. [Hu, 2024]. Se propone un enfoque estadístico que destaca los beneficios del análisis de componentes principales junto con esquemas de monitoreo multivariado con memoria. Los resultados obtenidos muestran que esta metodología tiene un alto potencial para identificar pequeñas anomalías en conjuntos de datos correlacionados. En el presente trabajo de investigación se muestra una metodología eficiente para interpretar y poder tener un análisis para señales fuera de control en un sistema de producción multivariante que trabaja en dos fases.

El procedimiento propuesto se desarrolla en dos fases. En la primera, se utiliza el gráfico de control MCUSUM con el objetivo de supervisar y controlar la calidad del sistema de producción. Ante la aparición de una señal fuera de control que indique un posible desajuste en el proceso, se activa la segunda fase. Esta consiste en identificar la fuente de variación mediante una red neuronal artificial del tipo

perceptrón multicapa. Así, los responsables del sistema productivo podrán detectar qué variable(s) originan el descontrol y aplicar acciones correctivas de manera oportuna, reduciendo la probabilidad de generar productos fuera de especificación.

2. Métodos

Aunque el caso de estudio se centra en un sistema de producción industrial perteneciente al sector electrónico, la metodología propuesta es aplicable a cualquier entorno productivo que requiera la supervisión simultánea de múltiples características de calidad. En el ámbito de la manufactura electrónica, cada componente, desde los diminutos microchips hasta los complejos circuitos impresos, cumple un rol esencial en la funcionalidad de los dispositivos utilizados cotidianamente. Entre estos elementos, la pasta de soldar se distingue por su relevancia en el proceso de ensamblaje [Wang, 2025]. La pasta de soldar es un compuesto utilizado para establecer uniones eléctricas entre los componentes electrónicos y las placas de circuito impreso (PCB) durante el ensamblaje. Su correcta aplicación resulta esencial para asegurar tanto la fiabilidad como el desempeño de los dispositivos electrónicos. Esta etapa del proceso de manufactura es considerada una de las más críticas, ya que influye de manera directa en la calidad y confiabilidad de las conexiones soldadas [Kong, 2024]. Con el progreso constante de la tecnología electrónica, emergen nuevos retos y tendencias en la producción en serie. Uno de los más relevantes es asegurar el control preciso de la calidad y cantidad de la pasta de soldar, especialmente en líneas de fabricación de alta velocidad. En estos entornos, incluso mínimas variaciones durante la aplicación de la pasta pueden comprometer la calidad y confiabilidad de las uniones soldadas [Zippelius, 2022]. El monitoreo del proceso de aplicación de pasta de soldadura requiere el uso de equipos especializados de inspección de pasta de soldadura (IPS), los cuales permiten evaluar los depósitos aplicados. Estos sistemas están diseñados para medir parámetros clave como el volumen, el área y la altura del depósito, asegurando así una dosificación precisa durante la impresión. Gracias a estas mediciones, los fabricantes pueden anticipar la calidad y confiabilidad a largo plazo de las uniones soldadas [Raj, 2016].

Para el estricto control sobre la aplicación de pasta de soldadura brinda a los fabricantes la oportunidad de identificar los defectos en las juntas de soldadura en una etapa temprana y así de esta manera, lograr resolver el problema oportunamente. Para esto contribuye que los fabricantes puedan ahorrar gastos imprevistos relacionados con la calidad para la aplicación de la pasta de soldar, ya que es una operación indispensable en el proceso de ensamble de tarjetas electrónicas.

Gráfico de control MCUSUM

La metodología inicia con la supervisión de la calidad del sistema de producción mediante el uso del gráfico de control MCUSUM. La construcción de este gráfico consta de dos etapas; la primera fase se enfoca en calcular las estadísticas de tendencia central y de dispersión para p características de calidad, siempre y cuando el proceso se mantenga bajo condiciones de control estadístico [Issam, 2008]. Como medida de tendencia central, el vector de medias muestral ($\bar{x}$) se define a partir de la Ecuación 1, se forma el vector de medias y este conformado por las p medias individuales ($\bar{x}_i$) de las características de calidad monitoreadas.

$$\bar{x} = [\bar{x}_1 \quad \bar{x}_2 \quad \bar{x}_3 \quad \cdots \quad \bar{x}_p] \quad (1)$$

La matriz de covarianzas muestral asociada al vector de medias (S), determinada a partir de la Ecuación 2. Donde la matriz es simétrica, en su diagonal aparecen las varianzas de las variables (S_i) y fuera de ellas las covarianzas entre cada par de variables (S_{ij}) de la p características de calidad [Knoth, 2021].

$$S = \begin{bmatrix} S_1^2 & S_{12}^2 & \cdots & S_{1p}^2 \\ S_{21}^2 & S_2^2 & \cdots & S_{2p}^2 \\ \vdots & \vdots & \ddots & \vdots \\ S_{p1}^2 & S_{p2}^2 & \cdots & S_p^2 \end{bmatrix} \quad (2)$$

El vector de medias y la matriz de covarianzas son el punto de partida para el control estadístico multivariable, ya que los gráficos de control multivariados solo son válidos cuando la variable tiende a seguir una distribución normal multivariable [Lin, 2016], cuya densidad ($f(x)$) viene dada a partir de la Ecuación 3. Donde x es el vector de mediciones de las características de calidad.

$$f(x) = (2\pi)^{-\frac{p}{2}} \det(S)^{-\frac{1}{2}} e^{\left[-\frac{1}{2}(x-\bar{x})^t S^{-1}(x-\bar{x})\right]} \quad (3)$$

Con la finalidad de ejemplificar la fase I de la construcción del gráfico de control multivariante MCUSU, se tienen 30 observaciones para cada una de las variables y a partir de datos tomados de la producción nos permitirá estimar el vector de medias y la matriz de covarianza (Tabla 1):

$$\bar{x} = [0.07810 \quad 0.61789 \quad 0.12779]$$

$$S = \begin{bmatrix} 0.00021215 & 0.00083064 & 0.00016859 \\ 0.00083064 & 0.00336860 & 0.00064334 \\ 0.00016859 & 0.00064334 & 0.00013930 \end{bmatrix}$$

Tabla 1 Mediciones de características de calidad tomadas en el proceso.

# Muestra	Volumen	Área	Altura
1	0.06717	0.55422	0.12145
2	0.66904	0.58734	0.11963
3	0.05250	0.52243	0.10648
...	...	...	...
30	0.09456	0.67708	0.14041

Fuente: elaboración propia

Posteriormente para poder continuar con el desarrollo del gráfico de control multivariado se vuelve a extraer una nueva muestra para mediciones de cada una de las características de calidad a monitorear en el proceso, en el cual permitirá verificar la estabilidad estadística en el sistema de fabricación, para este caso, la supervisión en la aplicación de la soldadura en el proceso de ensamble de las tarjetas electrónica. En Tabla 2 se tiene la muestra que será empleada para poder ejemplificar el desarrollo del gráfico de control MCUSUM. El estadístico MCUSUM (M_i) se calcula a partir de la Ecuaciones 4 a 6. Donde $k = 0.5$ y $R_0 = 0$ son dos constantes.

Tabla 2 Mediciones para desarrollar el grafico MCUSUM.

# Muestra	Volumen	Área	Altura
1	0.08471	0.64666	0.13409
2	0.06044	0.54679	0.11244
3	0.07460	0.60523	0.12670
...	...	...	...
30	0.07455	0.67708	0.12371

Fuente: elaboración propia

$$M_i^2 = [R_i' S^{-1} R_i]^{1/2} \quad (4)$$

$$R_i = \begin{cases} (R_{i-1} + x_i - \bar{x}) \left(1 - \frac{k}{C_i}\right) & \text{si } C_i > k \\ R_i = 0 & \text{si } C_i \leq k \end{cases} \quad (5)$$

$$C_i = [(R_{i-1} + x_i - \bar{x})' S^{-1} (R_{i-1} + x_i - \bar{x})]^{1/2} \quad (6)$$

La señal fuera de control se genera cuando $M_i^2 > h$, siendo h el límite superior de control del grafico (LSC). De acuerdo con [Montgomery, 2012], los valores de k y h que proporcionan una eficiencia apropiada del grafico MCUSUM son 0.5 y 5.5 respectivamente. Se muestran los valores de M^2 obtenidos mediante el software RStudio para así poder calcular los estadísticos del gráfico de control MCUSUM.


La Tabla 3 muestra los estadísticos MCUSUM para cada una de las observaciones que se utilizaron en su construcción del gráfico de control, el procedimiento es el mismo mostrado previamente para cada observación.

Tabla 3 Valores para cada observación del estadístico MCUSUM.

Muestra	M^2	Muestra	M^2	Muestra	M^2	Muestra	M^2
1	0.58	14	2.88	27	3.09	40	4.71
2	0.61	15	3.76	28	2.60	41	15.93
3	0.79	16	4.73	29	3.26	42	23.23
4	1.41	17	1.08	30	2.92	43	22.29
5	1.20	18	0.81	31	3.33	44	22.08
6	1.31	19	0.45	32	3.13	45	20.28
7	3.08	20	1.63	33	2.82	46	19.86
8	2.40	21	1.41	34	3.66	47	20.57
9	2.06	22	1.72	35	3.60	48	19.78
10	0.70	23	1.81	36	4.23	49	19.33
11	1.07	24	2.70	37	6.12		
12	0.29	25	3.87	38	6.82		
13	1.42	26	2.93	39	6.35		

Fuente: elaboración propia

En la Figura 1 se puede observar el grafico de control MCUSUM con resultado de la gráfica en los estadísticos y el límite de control. Se observa que las muestras números 37, 38, 39 y de la 41 hasta la 49 generan una señal fuera de control en el proceso de aplicación de la soldadura, por lo que en estas muestras se deberán analizar con el fin de identificar la naturaleza de la variación y así, con base a los resultados poder corregir el descontrol estadístico del proceso.



Fuente: elaboración propia

Figura 1 Gráfico de control multivariante MCUSUM.

Para el proceso de la aplicación de la soldadura en las tarjetas PCB en ambas graficas de control multivariante se pueden detectar señales fuera de control, con base a los resultados obtenidos podemos informar al responsable dentro del proceso y así deberá corregir el inconveniente en el sistema productivo que origino la variación, lo cual implicará tiempo, recursos y un análisis complementario. A continuación, se discutirá el desarrollo del sistema propuesto con base a una red neuronal artificial perceptrón multicapa para detectar cuál(es) de las p variable(s) analizada(s) está(n) fuera de control de forma automática.

RNA perceptrón multicapa

La RNA Perceptrón multicapa es una herramienta que se puede emplear para poder clasificar y modelar los comportamientos que no son lineales como los que comúnmente ocurren dentro en el sector industrial [Clark, 2025]. La arquitectura de una RNA perceptrón multicapa se forma por una capa de entrada, un numero arbitrario de capas ocultas y una capa de salida. Cada una de las neuronas que tienen las capas ocultas o de salida reciben una entrada de las neuronas de la capa previa, pero no existe conexiones laterales entre las neuronas dentro de cada capa [Majout, 2024]. La capa de entrada puede contener tantas neuronas como categorías correspondan a las variables independientes que se desean representar. La capa de salida corresponde a las que son las variables de respuesta. El funcionamiento

de la RNA son dos importantes tareas: Entrenamiento y prueba. Entrenar una RNA, es un proceso que modifica el valor de los pesos y bias asociados a cada neurona con el fin de que la RNA pueda, con base a unos datos presentados en la capa de entrada, generar así una salida. La tarea de prueba consiste en poder medir el nivel de error generado por la RNA al emitir en la salida datos del problema que no fueron incluidos en la tarea de entrenamiento [Jayasinghe, 2025]. En el conjunto de datos que son generados para la fase de entrenamiento es integrado por la simulación de cien eventos con variación en el vector de medias para cada una de las siete categorías posibles con niveles de 0.5σ , 1.5σ y 2.5σ , construyendo una matriz de entrenamiento de tamaño $[3 \times 2,100]$. En la Tabla 4, se muestra como establecer el entrenamiento con una variación de 0.5σ en el vector de medias para las siete posibles categorías del caso de aplicación industrial bajo estudio.

Tabla 4 Entrenamiento de la RNA.

Vector de entrenamiento	Origen de variación estadística	Categorías	Valor objetivo
$(0.07810 + 0.5\sigma, 0.61789, 0.12779)$	Variable 1	1	-1.000
$(0.07810, 0.61789 + 0.5\sigma, 0.12779)$	Variable 2	2	-0.666
$(0.07810, 0.61789, 0.12779 + 0.5\sigma)$	Variable 3	3	-0.333
$(0.07810 + 0.5\sigma, 0.61789 + 0.5\sigma, 0.12779)$	Variables 1 y 2	4	0.000
$(0.07810 + 0.5\sigma, 0.61789, 0.12779 + 0.5\sigma)$	Variables 1 y 3	5	0.333
$(0.07810, 0.61789 + 0.5\sigma, 0.12779 + 0.5\sigma)$	Variables 2 y 3	6	0.666
$(0.07810 + 0.5\sigma, 0.61789 + 0.5\sigma, 0.12779 + 0.5\sigma)$	Variables 1, 2 y 3	7	1.000

Fuente: elaboración propia

Para los valores objetivos que se requiere en la red artificial para efectuar la tarea de clasificación y reconocimiento de las diferentes categorías se asignan de acuerdo con la función de activación tangente hiperbólica, la cual puede tener valores continuos desde $[-1,1]$ y se asignaron de forma equidistante en el dominio de la función. La matriz de prueba se desarrolla a partir de datos simulados a partir de mediciones obtenidas del sistema de fabricación, los datos son clasificados en 200 vectores en los que se presentan diferentes magnitudes de variación en cada una de estas variables, la magnitud de variación que contempla es de: 1σ , 2σ y 3σ . Debido a que se tienen siete posibles categorías en la variable de respuesta y su matriz es de $[3 \times 4,200]$. Se desarrollan los conjuntos para el entrenamiento y prueba, para después construir la arquitectura de la RNA.

La eficiencia del método propuesto para el análisis de las señales fuera de control dependerá directamente de la precisión con la que en la red neuronal artificial lo clasifiquemos para los cambios ocurridos en las diferentes variables durante el proceso de fabricación. Para ello se debe lograr una eficiencia adecuada y es necesario establecer parámetros de operación correctos en la RNA, para conseguir dicho objetivo se realizó una experimentación. Las topologías de las RNA's propuestas en la Tabla 5, son arquitecturas que clasifican de forma adecuada los valores establecidos durante la fase del entrenamiento, por lo que se recurrió a un parámetro estadístico como es el error cuadrático medio (ECM|MSE) para determinar la topología que se debería de seleccionar para la fase de prueba y posteriormente resolver la tarea de la clasificación. Para la arquitectura de las redes neuronales artificiales que se desarrollaron de forma dinámica mediante la construcción del algoritmo que se basa en la experimentación exhaustiva y condicionada en ciclos con la finalidad de poder probar el total de posibles combinaciones de topología.

Tabla 5 Topología de RNA desarrolladas para la fase de entrenamiento.

Topología	1	2	3	4	5	6	7	8
Numero de neuronas	1450	1250	1395	1355	1472	1492	1544	1434
Taza de aprendizaje	0.005	0.005	0.01	0.005	0.01	0.005	0.005	0.01
Error permitido	1×10^{-4}	1×10^{-5}	1×10^{-4}	1×10^{-5}	1×10^{-4}	1×10^{-5}	1×10^{-4}	1×10^{-5}
Numero de iteraciones	2354	3420	1642	1711	1978	1619	1523	1647
MSE	0.087	0.082	0.091	0.086	0.097	0.097	0.094	0.095

Fuente: elaboración propia

Para el primer parámetro se consideró que el número de neuronas en la capa oculta con un intervalo de [5,2000]. Para el segundo parámetro es en una tasa de aprendizaje con el factor de incremento de 0.001 [0.005,0.9] Para el error permitido se estableció en solo dos únicas posibilidades 1×10^{-4} y 1×10^{-5} , y, por último, se programó una pausa en el entrenamiento para que, mediante el método del gradiente descendiente, si la función de error no mejora por lo menos en 0.001 durante 100 iteraciones. En cada arquitectura se registró una salida en una base de datos para proceder a calcular el error cuadrático medio frente a los valores objetivos que se establecieron previamente y esto fue el mecanismo para la

selección de las topologías. Esto nos permite tener una ventaja del procedimiento propuesto y asegurar un mínimo global y evitar caer en mínimos locales. En la Tabla 6, se puede observar la topología de la RNA seleccionada para llevar a cabo la tarea de clasificación de la(s) variable(s) generadora (s de variación en el sistema de fabricación con el fin de poder establecer de manera eficiente análisis del control estadístico del proceso multivariante a partir de la inteligencia artificial. Y una vez obtenidos los pesos y bias con los que opera la RNA la tarea de clasificación es automática, ya que solo involucra operaciones matriciales. Una vez que se analiza cada una de las muestras a través del gráfico de control MCUSUM y se detecta que existe una señal fuera de control estadístico como es el caso de la medición 37, es de suma importancia poder detectar la(s) variable(s) que están originando esta variación dentro del proceso con el fin de corregir de forma temprana en las condiciones de operación

Tabla 6 Topología seleccionada.

Parámetro	Valor asignado
Neuronas en capa oculta	1492
Función de activación	Tangente Hiperbólica
Taza de aprendizaje	0.005
Error permitido	1×10^{-5}
Número de iteración	1619
MSE	0.097
Tiempo de convergencia	00: 00: 52

Fuente: elaboración propia

3. Resultados

Con base a los datos recabados y su posterior análisis podemos validar el desempeño de las topologías que tienen las redes neuronales artificiales (RNA) y así analizar la fuente de variación y detectar mediante el grafico de control multivariante MCUSUM, para proceder a comparar los resultados en función de desempeño, sensibilidad, especificaciones y exactitud. Mediante las Ecuaciones 7 a 9 se obtiene la probabilidad de no cometer el error tipo II ($1 - \beta$), a este argumento se le conoce como la potencia de la prueba, equivalente a la sensibilidad. Donde VP es el verdadero Positivo, VN el verdadero Negativo y FS el falso Negativo.

$$Sensibilidad = \frac{VP}{VP + FN} \quad (7)$$

$$Especificidad = \frac{VN}{VN + FP} \quad (8)$$

$$Exactitud = \frac{VP + VN}{VP + FP + FN + VN} \quad (9)$$

La probabilidad de cometer el error tipo I ($1 - \alpha$), se le conoce como eficiencia de la prueba, esto es la especificad. El grado de exactitud de esta prueba se puede definir como la proporción de casos en donde el resultado es correcto [Daniel, 2024]. Estos resultados que fueron generados por la RNA empleada para el análisis de la variación estadística que se genera en el proceso de aplicación de la pasta de la soldadura al introducir la matriz de prueba como se muestra en la Tabla 7.

Tabla 7 Resultado generados por la red neuronal Multicapa Perceptrón.

	Categoría	Sensibilidad	Especificación	Precisión
	1	0.9839	0.9899	0.9506
	2	0.9616	0.9743	0.9658
	3	0.9622	0.9982	0.9818
1σ	4	0.9582	0.9907	0.9751
	5	0.9867	0.9441	0.9593
	6	0.9546	0.9815	0.9543
	7	0.9517	0.9811	0.9832
	Promedio	0.9655	0.9871	0.9671
	1	0.9776	0.9901	0.9796
	2	0.9737	0.9709	0.9561
	3	0.9687	0.9604	0.9744
2σ	4	0.9628	0.9778	0.9663
	5	0.9656	0.9635	0.9619
	6	0.9867	0.9674	0.9584
	7	0.9564	0.9624	0.9596
	Promedio	0.9702	0.9703	0.9651
	1	0.9803	0.9812	0.9634
	2	0.9866	0.9749	0.9867
	3	0.9765	0.9714	0.9776
3σ	4	0.9702	0.9813	0.9911
	5	0.9754	0.9852	0.9841
	6	0.9773	0.9891	0.9784
	7	0.9969	0.9655	0.9738
	Promedio	0.9804	0.9783	0.9793

Fuente: elaboración propia

Con base en la Tabla 7 podemos identificar que la RNA perceptrón multicapa tiene un promedio del 96.71% para poder detectar los cambios con magnitudes que promedian una desviación estándar en las características de calidad del proceso de fabricación, esto se traduce que en el monitoreo estricto del proceso respecto a la exactitud de la RNA perceptrón multicapa la cual se entrenó, puede clasificar los

incrementos de la variación en dos y tres desviaciones estándar dentro de la operación para aplicar la pasta de soldadura, la exactitud se incrementa a 96.51 y 97.93% respectivamente. Para el aumento de la exactitud se puede tener una lógica de que, al incurrir en una mayor variación dentro del proceso de fabricación, la medición que origina dicha señal de que esta fuera de control como una alerta en el gráfico de control MCUSUM, se encontrara alejada del promedio y por consecuencia sería más fácil la clasificación a partir de una RNA multicapa perceptrón

4. Discusión

En los entornos industriales actuales, donde predomina la automatización, es fundamental implementar mecanismos que aseguren un control eficiente de la calidad, incluso en producciones de gran escala, donde se requiere una supervisión constante sobre posibles desviaciones respecto a las especificaciones de calidad acordadas.

El enfoque multivariado propuesto permite un control riguroso y preciso de las características críticas de calidad mediante la integración del gráfico de control MCUSUM y una red neuronal artificial del tipo perceptrón multicapa. Esta metodología ofrece la capacidad de procesar grandes volúmenes de datos en poco tiempo, alcanzando niveles de precisión promedio de 96.71, 96.51 y 97.93% ante desviaciones equivalentes a 1σ , 2σ y 3σ , respectivamente. La efectividad del enfoque radica tanto en la sensibilidad del gráfico MCUSUM para detectar pequeñas variaciones, como en la habilidad de la RNA para clasificarlas con alta exactitud.

5. Conclusiones

A partir de los resultados obtenidos con la RNA perceptrón multicapa en el análisis de la variabilidad presente en sistemas de producción multivariantes, se observa que esta herramienta es capaz de identificar señales fuera de control. Esto se debe a que una desviación de 1σ no siempre genera una alerta visible en el gráfico de control MCUSUM. No obstante, la RNA logra interpretar y clasificar eficientemente la fuente de variabilidad, proporcionando un diagnóstico más preciso

del comportamiento del proceso de fabricación, incluso ante cambios sutiles que podrían pasar desapercibidos por métodos estadísticos tradicionales.

6. Referencias y Bibliografía

- [1] Aguado, D., Ferrer, A., Ferrer, J., & Seco, A. (2007). Multivariate SPC of a sequencing batch reactor for wastewater treatment. *Chemometrics And Intelligent Laboratory Systems*, 85(1), 82-93. <https://doi.org/10.1016/j.chemolab.2006.05.003>.
- [2] Ahsan, M., Mashuri, M., Khusna, H., & Wibawati, N. (2022). Kernel principal component analysis (PCA) control chart for monitoring mixed non-linear variable and attribute quality characteristics. *Heliyon*, 8(6), e09590. <https://doi.org/10.1016/j.heliyon.2022.e09590>.
- [3] Anojahatlo, K., & Sabri-Laghaie, K. (2022). Enhancing the detection power of multivariate time between events control charts for Gumbel's bivariate exponential distribution. *Computers & Industrial Engineering*, 171, 108215. <https://doi.org/10.1016/j.cie.2022.108215>.
- [4] Bays, H. E., Fitch, A., Cuda, S., Gonsahn-Bollie, S., Rickey, E., Hablutzel, J., Coy, R., & Censani, M. (2023). Artificial intelligence and obesity management: An Obesity Medicine Association (OMA) Clinical Practice Statement (CPS) 2023. *Obesity Pillars*, 6, 100065 <https://doi.org/10.1016/j.obpill.2023.100065>.
- [5] Calabrò, A., Marchetti, E., PawełSkrzypek, N., & Marchel, J. (2025). CONCERN: A model-based monitoring infrastructure. *Internet Of Things*, 101557. <https://doi.org/10.1016/j.iot.2025.101557>.
- [6] Chen, J., Shao, Z., Zhu, H., Chen, Y., Li, Y., Zeng, Z., Yang, Y., Wu, J., & Hu, B. (2023). Sustainable interior design: A new approach to intelligent design and automated manufacturing based on Grasshopper. *Computers & Industrial Engineering*, 183, 109509. <https://doi.org/10.1016/j.cie.2023.109509>.
- [7] Clark, C. A., Behrendt, M. G., Long, T., & Dauer, J. T. (2025). Neural responses to errors in models and their relevance for longer term learning among undergraduate life sciences students. *Trends In Neuroscience And Education*, 100253. <https://doi.org/10.1016/j.tine.2025.100253>.

- [8] Daniel, V. A. A., Vijayalakshmi, K., Pawar, P. P., Kumar, D., Bhuvanesh, A., & Christilda, A. J. (2024). Enhanced affinity propagation clustering with a modified extreme learning machine for segmentation and classification of hyperspectral imaging. *e-Prime - Advances In Electrical Engineering Electronics And Energy*, 9, 100704. <https://doi.org/10.1016/j.prime.2024.100704>.
- [9] De Almeida Moreira, B. R., Cruz, V. H., Cunha, M. L. O., & Da Silva Viana, R. (2021). Full-scale production of high-quality wood pellets assisted by multivariate statistical process control. *Biomass And Bioenergy*, 151, 106159. <https://doi.org/10.1016/j.biombioe.2021.106159>.
- [10] De Lima, S. M., Silva, B. F. A., Pontes, D. V., Pereira, C. F., Stragevitch, L., & Pimentel, M. F. (2013). In-line monitoring of the transesterification reactions for biodiesel production using NIR spectroscopy. *Fuel*, 115, 46-53. <https://doi.org/10.1016/j.fuel.2013.06.057>.
- [11] Dittrich, I., Gertz, M., Maassen-Francke, B., Krudewig, K., Junge, W., & Krieter, J. (2022). Estimating risk probabilities for sickness from behavioural patterns to identify health challenges in dairy cows with multivariate cumulative sum control charts. *Animal*, 16(8), 100601. <https://doi.org/10.1016/j.animal.2022.100601>.
- [12] Dutoit, C., Dehombreux, P., Lorphèvre, E. R., & Equeter, L. (2019). Statistical Process Control and Maintenance Policies for Continuous Production Systems Subjected to Different Failure Impact Models: Literature Review. *Procedia CIRP*, 86, 55-60. <https://doi.org/10.1016/j.procir.2020.01.050>.
- [13] Hoga, Y. (2016). Monitoring multivariate time series. *Journal Of Multivariate Analysis*, 155, 105-121. <https://doi.org/10.1016/j.jmva.2016.12.003>.
- [14] Hu, W., Jiao, Q., Liu, H., Wang, K., Jiang, Z., Wu, J., Cong, F., & Hao, G. (2024). A transferable diagnosis method with incipient fault detection for a digital twin of wind turbine. *Digital Engineering.*, 1, 100001. <https://doi.org/10.1016/j.dte.2024.100001>.
- [15] Issam, B. K., & Mohamed, L. (2008). Support vector regression based residual MCUSUM control chart for autocorrelated process. *Applied Mathematics And Computation*, 201(1-2), 565-574. <https://doi.org/10.1016/j.amc.2007.12.059>.

- [16] Jayasinghe, S., Mahmoodian, M., Alavi, A., Sidiq, A., Shahrivar, F., Sun, Z., Thangarajah, J., & Setunge, S. (2025). A review on the applications of artificial neural network techniques for accelerating finite element analysis in the civil engineering domain. *Computers & Structures*, 310, 107698. <https://doi.org/10.1016/j.compstruc.2025.107698>.
- [17] Knoth, S., & Schmid, W. (2021). *Frontiers in Statistical Quality Control 13*. En Springer eBooks. <https://doi.org/10.1007/978-3-030-67856-2>.
- [18] Kong, D., Hu, X., Zhang, J., Liu, X., & Zhang, D. (2024). Design of intelligent inspection system for solder paste printing defects based on improved YOLOX. *iScience*, 27(3), 109147. <https://doi.org/10.1016/j.isci.2024.109147>.
- [19] Lin, T., McLachlan, G. J., & Lee, S. X. (2015). Extending mixtures of factor models using the restricted multivariate skew-normal distribution. *Journal Of Multivariate Analysis*, 143, 398-413. <https://doi.org/10.1016/j.jmva.2015.09.025>.
- [20] Lokuge, S., Sedera, D., Grover, V., & Sarker, S. (s. f.). Orchestrating Digital Technologies with Incumbent Enterprise Systems for Attaining Innovation. *Information & Management*, 104066. <https://doi.org/10.1016/j.im.2024.104066>.
- [21] Majout, B., Bossoufi, B., Karim, M., Skruch, P., Mobayen, S., Mourabit, Y. E., & Laggoun, Z. E. Z. (2024). Artificial neural network-based direct power control to enhance the performance of a PMSG-wind energy conversion system under real wind speed and parameter uncertainties: An experimental validation. *Energy Reports*, 11, 4356-4378. <https://doi.org/10.1016/j.egyr.2024.03.039>.
- [22] Melanie, S., Benedikt, K., Pfaffl, M. W., & Irmgard, R. (2015). The potential of circulating extracellular small RNAs (smexRNA) in veterinary diagnostics— Identifying biomarker signatures by multivariate data analysis. *Biomolecular Detection And Quantification*, 5, 15-22. <https://doi.org/10.1016/j.bdq.2015.08.001>.
- [23] Miekley, B., Stamer, E., Traulsen, I., & Krieter, J. (2013). Implementation of multivariate cumulative sum control charts in mastitis and lameness monitoring. *Journal Of Dairy Science*, 96(9), 5723-5733. <https://doi.org/10.3168/jds.2012-6460>.

- [24] Monaco, S., Apiletti, D., Francica, A., & Cerquitelli, T. (2025). Quantify production planning efficiency through predictive modeling in manufacturing systems. *Computers & Industrial Engineering*, 110919. <https://doi.org/10.1016/j.cie.2025.110919>.
- [25] Montgomery, D. C. (2012b). *Statistical quality control*. John Wiley & Sons.
- [26] Oakland, J. S. (2008b). *Statistical process control*. Routledge. Butterworth-Heinemann.
- [27] Raj, J. J. R., Rahman, S., & Anand, S. (2016). 8051 microcontroller to FPGA and ADC interface design for high speed parallel processing systems – Application in ultrasound scanners. *Engineering Science And Technology An International Journal*, 19(3), 1416-1423. <https://doi.org/10.1016/j.jestch.2016.04.004>.
- [28] Richter, L., Lehna, M., Marchand, S., Scholz, C., Dreher, A., Klaiber, S., & Lenk, S. (2022). Artificial Intelligence for Electricity Supply Chain automation. *Renewable And Sustainable Energy Reviews*, 163, 112459. <https://doi.org/10.1016/j.rser.2022.112459>.
- [29] Wang, J., Deng, Y., Zhang, Z., Jin, J., & Liu, P. (2025). Thermal Stress Behavior and Optimization of Solder Joints in CSP-LED Packages. *Results In Engineering*, 104712. <https://doi.org/10.1016/j.rineng.2025.104712>.
- [30] Xu, Y., Chi, M., Lee, C., Chong, H., & Skitmore, M. (2025). Effect of blockchain and inter-organizational trust on collaboration between contractors and supply chain partners. *Ain Shams Engineering Journal*, 16(6), 103396. <https://doi.org/10.1016/j.asej.2025.103396>.
- [31] Yao, W., Li, D., & Gao, L. (2022). Fault detection and diagnosis using tree-based ensemble learning methods and multivariate control charts for centrifugal chillers. *Journal Of Building Engineering*, 51, 104243. <https://doi.org/10.1016/j.job.2022.104243>.
- [32] Zippelius, A., Hanß, A., Schmid, M., Pérez-Velázquez, J., & Elger, G. (2022). Reliability analysis and condition monitoring of SAC+ solder joints under high thermomechanical stress conditions using neuronal networks. *Microelectronics Reliability*, 129, 114461. <https://doi.org/10.1016/j.microrel.2021.114461>.