

**IMPLEMENTACIÓN DE UNA HERRAMIENTA PARA CLASIFICAR PATRONES
DE COMPORTAMIENTO EN CARTAS DE CONTROL UNIVARIADAS**

JOSÉ FERNANDO GARCÍA MARÍN

**UNIVERSIDAD DEL VALLE
FACULTAD DE INGENIERIA
ESCUELA DE INGENIERIA INDUSTRIAL
PROGRAMA ACADÉMICO DE INGENIERÍA INDUSTRIAL
ZARZAL
2014**

**IMPLEMENTACIÓN DE UNA HERRAMIENTA PARA CLASIFICAR PATRONES
DE COMPORTAMIENTO EN CARTAS DE CONTROL UNIVARIADAS**

JOSÉ FERNANDO GARCÍA MARÍN

**Trabajo de grado presentado para optar por el título de
INGENIERO INDUSTRIAL**

**Director del proyecto
Ing. Julián González Velasco**

**UNIVERSIDAD DEL VALLE
FACULTAD DE INGENIERIA
ESCUELA DE INGENIERIA INDUSTRIAL
PROGRAMA ACADÉMICO DE INGENIERÍA INDUSTRIAL
ZARZAL
2014**

Nota de aceptación:

Jurado

Jurado

DEDICATORIA

Como un padre siempre te he visto y como una madre también, gracias a su sabiduría influyeron en mi madurez para lograr los objetivos en la vida, y me han dado mis valores, principios, carácter, empeño, perseverancia y coraje para conseguir mis objetivos.

A mi madre, que Dios la tiene en su gloria y recuerdo todos los días de mi vida.

A mi familia quienes por ellos soy quien soy

A todos quienes de alguna manera contribuyeron a mi formación en esta etapa de mi vida

José Fernando García Marín

AGRADECIMIENTOS

A Dios por bendecirme para llegar hasta donde he llegado.

A mi familia y abuelos, Octavio Marín y Rubiela López quienes fueron mi motor incondicional a lo largo de la carrera.

Al profesor Julián González por su dirección en esta investigación.

A la Universidad del Valle y a todos los profesores que contribuyeron a mi realización como profesional.

A mis compañeros y amigos que de una manera u otra acompañaron esta etapa de mi vida.

TABLA DE CONTENIDO

	pág.
TABLA DE CONTENIDO	6
LISTA DE ANEXOS	10
GLOSARIO	11
RESUMEN	13
ABSTRACT	14
INTRODUCCIÓN	15
1 PROBLEMA DE INVESTIGACIÓN	16
1.1 DESCRIPCIÓN DEL PROBLEMA	16
1.2 FORMULACIÓN DEL PROBLEMA	17
1.2.1 Sistematización del problema	17
1.3 DELIMITACIÓN DEL PROBLEMA	18
2 JUSTIFICACIÓN	19
3 OBJETIVOS	20
4 MARCO REFERENCIAL	21
4.1 GRAFICOS DE CONTROL	21
4.1.1 Interpretación de gráficos de control	22
4.2 MAQUINAS DE SOPORTE VECTORIAL (SVM)	23
4.3 ARBOLES DE DECISIÓN (DT)	25
4.4 REDES NEURONALES ARTIFICIALES (ANN)	25
4.5 SINTESIS	27
5 SELECCIÓN DEL CLASIFICADOR	29
5.1 SELECCIÓN DE LA HERRAMIENTA	29
5.2 SELECCIÓN DEL MODELO	30
6 ¿QUE SON LAS REDES NEURONALES ARTIFICIALES (ANN'S)?	32
6.1 HISTORIA DE LAS ANN'S	32
6.2 REDES NEURONALES BIOLÓGICAS	34
6.3 FUNDAMENTOS DE LAS ANN'S	35
6.4 CARACTERISTICAS DE LAS ANN'S	36
6.4.1 Arquitectura de las ANN's	36
6.4.2 Propiedades de las ANN's	37
6.5 MODELO MULTILAYER PERCEPTRON (MLP)	37
6.5.1 Aprendizaje del MLP	38
6.5.2 Funcionamiento del algoritmo <i>Backpropagation</i>	38
6.6 RECAPITULACIÓN: VENTAJAS Y DESVENTAJAS DE LAS ANN'S	40
7 PLANTEAMIENTO DEL MODELO	41
7.1 CONCEPTUALIZACIÓN DEL MODELO	41
7.2 VARIABLES DEL MODELO	42
7.3 FORMULACIÓN DEL MODELO	43
7.3.1 Patrones de muestra	43
7.3.2 Estructura del modelo	45
7.3.3 Configuración del modelo	46
7.3.4 Funciones de transferencia	46

7.3.5	Algoritmo de entrenamiento	47
7.3.6	Entrenamiento y validación	47
7.3.7	Fase de clasificación	50
7.4	RESULTADOS DEL ENTRENAMIENTO.....	50
7.4.1	Elección del clasificador	50
7.4.2	Generalidades del entrenamiento	52
7.4.3	Estado del modelo.....	53
7.4.4	Matriz de confusión	55
8	CASO DE ESTUDIO	57
8.1	EVALUACIÓN DEL CASO DE ESTUDIO.....	58
9	CONCLUSIONES	60
10	BIBLIOGRAFÍA	62
	ANEXOS.....	65

LISTA DE TABLAS

Tabla 1. Cerebro frente a computador convencional	32
Tabla 2 Salidas por cada patrón	43
Tabla 4. Parámetros del modelo	48
Tabla 5. Porcentaje de precisión en el entrenamiento	50
Tabla 6. Desempeño promedio de la arquitectura del entrenamiento.....	51
Tabla 7. Desempeño promedio de los grupos de entrenamiento.....	52
Tabla 8. Matriz de pesos segunda capa	54
Tabla 9. Umbrales de activación.....	54
Tabla 10. Matriz de confusión	56
Tabla 11. Parámetros del gráfico caso de estudio	57
Tabla 12. Resultados del caso de estudio	59

LISTA DE FIGURAS

Figura 1 Patrones presentados en gráficos de control.....	22
Figura 2. Resultados matriz de comparación autor-modelo.....	31
Figura 3. Neurona biológica.....	34
Figura 4. Modelo de neurona artificial.....	36
Figura 6. Multilayer perceptron	45
Figura 7. Función de transferencia tangente hiperbólica	47
Figura 8. Proceso de entrenamiento del modelo	49
Figura 9. Estado del entrenamiento	53
Figura 10. Gráfico de control caso de estudio.....	58

LISTA DE ANEXOS

Anexo 1. Matriz de comparación modelo-autor.....	65
Anexo 2. Causas de variación	66
Anexo 3. Fase de entrenamiento 1	66
Anexo 4. Fase de entrenamiento 2	67
Anexo 5. Fase de entrenamiento 3	67
Anexo 6. Fase de entrenamiento 4	67
Anexo 7. Fase de entrenamiento 5	68
Anexo 8. Fase de entrenamiento 6	68
Anexo 9. Fase de entrenamiento 7	68
Anexo 10. Fase de entrenamiento 8	69
Anexo 11. Fase de entrenamiento 9	69
Anexo 12. Fase de entrenamiento 10	69
Anexo 13. Matrices de confusión	70
Anexo 14. Matriz de pesos primera capa.....	71
Anexo 15. Datos caso de estudio	72
Anexo 16. Script del modelo	73

GLOSARIO

A

Algoritmo de aprendizaje: Es un conjunto de reglas o instrucciones definidas y ordenadas para ejecutar la actualización de los pesos y de la red neuronal

Árboles de decisión: Técnica utilizada para construir diagramas de construcciones lógicas, que sirven para categorizar una serie de condiciones dadas. DT por sus siglas en inglés.

Axón: Prolongación de las neuronas conductoras de los impulsos nerviosos hacia otra neurona previamente procesados en el soma.

B

Backpropagation: Algoritmo para el entrenamiento de redes neuronales artificiales, basado en la propagación del error hacia atrás.

C

Causas asignables: Son causas que producen variaciones pronunciadas, haciendo que el proceso se halle fuera de control.

Causas comunes: Su aparición es casi inevitable y debido al azar, provocando un pequeño efecto en la variación total del proceso.

D

Dendritas: Ramificaciones de las neuronas dedicadas a la recepción de impulsos nerviosos.

E

Estructura Von Neumann: Es una arquitectura que emplea una unidad de procesamiento conectada a una entrada y una salida, dedicada a realizar series de cálculos complejos a gran velocidad.

F

Función de activación: Transforma el estado actual de activación en una señal de salida generalmente en un rango específico.

G

Gráficos de control: Es un esquema que representa el comportamiento de un proceso anotando sus datos ordenados en el tiempo.

I

Inconformidades en los procesos: Es la variación de los procesos fuera de los estándares previamente establecidos.

M

Máquinas de soporte vectorial: Herramienta utilizada en la inteligencia artificial para el reconocimiento de patrones en diferentes aspectos. SVM por sus siglas en inglés.

Modelo de clasificación: Es una representación de uno o varios sistemas dedicados a problemas que tienen que ver con clasificación.

Multilayer perceptrón: Modelo utilizado en varias publicaciones dedicadas al reconocimiento de patrones. Perceptrón multicapa en español.

P

Patrones de inestabilidad: Son guías que dan cuenta de la no aleatoriedad en los procesos en los gráficos de control.

R

Redes neuronales artificiales: Técnica de inteligencia artificial que intenta simular el funcionamiento del sistema neuronal biológico en sus funciones básicas.

Redes Recurrentes: Son tipos de redes neuronales artificiales con una interconexión mas robusta, enlazando neuronas en la misma capa.

Redes Feedforward: Son tipos de redes neuronales artificiales con sus conexiones exclusivamente hacia las capas siguientes.

S

Sinapsis: Es la unión entre neuronas donde se lleva a cabo la transmisión de impulsos o información.

Soma: Es el cuerpo celular de las neuronas, donde se procesa la información recibida.

T

Teoría reticularista: Teoría que sostenía que el sistema nervioso se conformaba de una retícula continua y no por millones de células interconectadas.

U

Umbral: Es un valor que representa el nivel de estímulo que debe tener una neurona para ser activada.

RESUMEN

El control de la calidad de los productos, es una parte fundamental en las organizaciones que pretenden sobrevivir en mercados competentes, y globalizados, como los que se viven hoy en día. El control estadístico de procesos, es una herramienta para asegurar la calidad de los productos. Por lo tanto, diagnosticar el estado de control de la producción, mediante gráficos de control, es un proceso que requiere la mayor atención posible. Este diagnóstico tradicionalmente es realizado de forma manual por personal no calificado y con poca experiencia en este tipo de herramientas. Esto implica problemas como carencia de objetividad y precisión en la identificación de variaciones no naturales.

En esta investigación se analizan algunas de las diferentes herramientas inteligentes, direccionadas al reconocimiento de patrones de inestabilidad en gráficos de control, y se examinan algunos modelos relacionados con el tema. Se hace una selección de la herramienta que se cree es la más apropiada para la clasificación de patrones, tomando en cuenta criterios implícitos expuestos por autores de las diferentes investigaciones referenciadas en este estudio.

Al considerar ciertos criterios para la selección de la herramienta de clasificación, se elige a las redes neuronales artificiales como el método de reconocimiento de patrones apropiado, además se hace una breve descripción acerca de su funcionamiento y características.

En seguida, se desarrolla el modelo basado en redes neuronales artificiales, utilizando algunos parámetros considerados por distintos autores para su desarrollo, y se hace un análisis de las variables implicadas.

Finalmente, se evalúa el modelo mediante un caso de estudio con datos reales para la verificación del estado de control de un proceso. Esta información es proporcionada por una empresa del sector azucarero en el Valle del Cauca.

Palabras clave: Control de calidad, control estadístico de procesos, gráficos de control, patrones de inestabilidad, variaciones no naturales.

ABSTRACT

The products' control quality, is a fundamental part in the organizations that pretend to survive in competent and globalized markets, as nowadays ones. The estatistical control of processes is a tool to assure the quality of products.

Therefore, diagnosing the control state of the production, by control graphics, is a process that requires the most possible attention. This diagnosis isn usually done in a manual form for unqualified people and inexperienced in the topic. This involves troubles like lack of objectiveness and accuracy when identifying non-natural variations.

In this research, some of the different intelligent tools are being analized, adressed to the recognizement of unestability patterns in control graphics, and some models related to the topic are examined. An election of the tool is made, taking into account the most appropriate for the patterns classification, considering implicit criteria for the autors of the different researches referred in this study.

When considering several criteria for the classification tool selection, it's chosen the artificial neuronal networks as the recognizing method of appropriate patterns, besides, it's made a short description about its performance and characteristics.

Then, it's developed the model based on artificial neuronal networks, using some parameters considered for different autors for its design, and it's made an analysis of the involved variables.

Finally, it's the model is evaluated through a study case with real data for the verification of the control estate of a process. The data is given by a sugar cane company in Valle del Cauca.

Key words: Quality control, statistical control of processes, control graphics, unestability patterns, non-natural variations.

INTRODUCCIÓN

Las exigencias de un mundo cada vez más globalizado, obligan a las compañías a mejorar sus estrategias para permanecer en el mercado actual. Uno de los aspectos más importantes que hoy en día consideran las organizaciones para mantenerse en el mercado, es la calidad de sus productos. Por esto, el control estadístico de procesos es un factor determinante para asegurar la calidad de la producción.

Los gráficos para el control estadístico de procesos, es un concepto propuesto por el Dr. Walter Shewart, que toma gran relevancia desde la segunda guerra mundial, y debido a su impacto y pertinencia, es hoy la base para cumplir con las especificaciones de calidad requeridas por estándares establecidos. Estos gráficos entregan información acerca del estado de control de determinado proceso, al ser interpretados previamente siguiendo unas directrices establecidas. La interpretación de estos gráficos es hecha tradicionalmente de forma manual, por personal poco especializado en este procedimiento, con la obligación de tener suficiente capacidad y experiencia. Este hecho, conlleva al riesgo de asumir un bajo nivel de objetividad, y no muy buena precisión al analizar los gráficos en algunos casos.

Por estas razones, y con el objetivo de disminuir los inconvenientes que tiene diagnosticar tradicionalmente los gráficos de control, se pretende aplicar una herramienta encaminada a clasificar patrones de inestabilidad en gráficos de control, y de este modo agilizar la toma de decisiones respecto al comportamiento de los procesos.

Tomando en cuenta esto, se hace una revisión de distintas investigaciones que se han desarrollado con el objetivo de mitigar este tipo de imprecisiones, utilizando herramientas inteligentes de reconocimiento de patrones. Estas investigaciones han sido enfocadas a diagnosticar el estado de los procesos, mediante el análisis de los gráficos de control. Un análisis detallado de 27 investigaciones se realiza con el fin de determinar la herramienta más apropiada para la aplicación en un proceso real, dando como resultado que las redes neuronales artificiales presentan ventajas, respecto a otros métodos, considerando criterios propuestos por diferentes autores en sus publicaciones.

En cuanto a las redes neuronales artificiales, en el capítulo 6, se presenta una breve descripción de sus fundamentos, funcionamiento, ventajas y desventajas. Seguidamente, en el planteamiento del modelo se detalla su conceptualización y se describen las variables involucradas. En seguida, se presenta la formulación de un modelo, así como sus resultados y nivel de precisión. Finalmente, para hacer el análisis práctico de la red neuronal, se hace una evaluación mediante un caso de estudio de un proceso real en la industria, presentando los resultados y conclusiones acerca de los mismos.

1 PROBLEMA DE INVESTIGACIÓN

1.1 DESCRIPCIÓN DEL PROBLEMA

El control de calidad es una estrategia competitiva que permite a las compañías tener alto grado de aceptabilidad entre sus consumidores. Debido a esto y hasta la segunda guerra mundial, las pruebas de calidad eran utilizadas por las empresas basándose principalmente en la inspección de productos terminados, y eliminando o reprocesando la producción defectuosa. Este proceso se evidenció ineficaz por el consumo poco eficiente de los recursos en unidades no conformes, hasta que se empezó a desarrollar técnicas para el control de los procesos a nivel estadístico.

Este proceso de calidad permaneció de esta manera hasta 1931, con los trabajos de Walter Andrew Shewart en los laboratorios de *Bell Telephone*, principalmente por su obra *Economic Control of Quality of Manufactured Product*, donde propone trasladar el aseguramiento de la calidad al proceso de manufactura, adaptando gráficos para el control de procesos paralelamente a la etapa de fabricación de los productos. Por tal razón, el control estadístico de procesos, se ha convertido hasta hoy en herramienta inamovible, la cual ayuda a reducir la producción defectuosa, de igual forma, mantiene la mejora continua y compara la producción con los estándares de calidad establecidos (Prat, Tort-Martorel, Grima, & Pozueta, 1998).

Estos gráficos para el control de procesos, han evolucionado a través del tiempo, adquiriendo ciertos cambios en su interpretación y estructura, pero conservando el principio planteado desde su publicación; y su construcción depende fundamentalmente de la media (μ) y la variabilidad o desviación (σ) del proceso (Montgomery, 1992).

La utilización de estos gráficos es primordial para determinar si los procesos tienen el comportamiento esperado, o están siendo afectados por causas no naturales. El comportamiento que se espera de un proceso está afectado por un alto número de variables (por ejemplo variaciones de temperatura, humedad ambiental, entre otras) que inciden en este, provocando cambios en las características del producto. Estas variaciones son pequeñas y no generan ningún tipo de patrón predominante, por tal razón, se espera que estas características se distribuyan normalmente, y son llamadas causas comunes¹. Las causas no naturales por el contrario, si el proceso muestra un patrón predominante, entonces este no se encuentra distribuido normalmente, y se dice que el proceso está fuera

¹ **Causas comunes:** Su aparición es casi inevitable y debido al azar, provocando un pequeño efecto en la variación total. Cuya eliminación, es responsabilidad de la dirección de la empresa y abarcan alrededor del 90% de los problemas de calidad.

de control, al revelar presencia de no aleatoriedad. Estas son llamadas causas asignables² (Prat, Tort-Martorel, Grima, & Pozueta, 1998).

Para interpretar estos gráficos, se debe tener en cuenta un grupo de patrones que enmarcan la irregularidad del proceso, y que pueden dar cuenta de la existencia de causas asignables en este. Estos patrones están divididos esencialmente en seis: normal, tendencia hacia abajo, tendencia hacia arriba, cambio hacia abajo, cambio hacia arriba y cíclico (Hassan, Shariff, Shaaroun, & Jamaluddin, 2003). Al detectar la presencia de un patrón de este tipo en los gráficos de control (excepto el patrón normal), se deben tomar acciones al respecto para eliminar las causas que ocasionan la inestabilidad.

La interpretación de estos gráficos, generalmente se ejecuta de forma manual por personal no especializado, lo cual provoca cierto nivel de fallas al graficar o interpretar patrones que no sean fácilmente reconocibles. También el reducido nivel de objetividad alcanzado por las personas responsables en la verificación de los gráficos, es un factor que afecta ampliamente su interpretación, teniendo así, alto riesgo de análisis errado o de incurrir en sesgos. Estos procedimientos suelen resultar dispendiosos, los cuales deben ser ejecutados por personal con experticia y experiencia, convirtiéndose en agentes críticos para asegurar la calidad de los productos, por lo cual se puede pensar en otras alternativas para interpretar los gráficos de control.

1.2 FORMULACIÓN DEL PROBLEMA

¿Cómo identificar el comportamiento de procesos en cartas de control univariadas mediante la implementación de una herramienta computarizada?

1.2.1 Sistematización del problema

- ¿Cuáles son los patrones de control utilizados en el control estadístico de procesos y sus principales características?
- ¿Qué herramientas se han desarrollado para la identificación de patrones?
- ¿Es posible integrar herramientas de identificación de patrones para el control de procesos?
- ¿La herramienta a desarrollar identifica patrones en los procesos bajo observación?

² **Causas asignables:** Son causas que producen variaciones pronunciadas, haciendo que el proceso se halle fuera de control. Su eliminación es sencilla y son responsabilidad del operario, representando menos del 10% de los problemas de calidad de un cierto proceso. (Prat, Tort-Martorel, Grima, & Pozueta, 1998)

1.3 DELIMITACIÓN DEL PROBLEMA

El presente proyecto, abarca una investigación enfocada al control de calidad, específicamente hacia el control estadístico de procesos, mediante las cartas de control de univariadas, las cuales son utilizadas a menudo por las empresas de manufactura.

La interpretación de estos gráficos es clave para la buena gestión del proceso de producción como tal, por lo tanto, es indispensable una búsqueda exhaustiva acerca de las herramientas existentes para interpretar estos gráficos, y las técnicas que se utilizan hoy en día en el campo laboral. En las organizaciones donde se utiliza el control estadístico de procesos, como herramienta para asegurar la calidad de los productos, se utilizan métodos tradicionales para inferir acerca del estado de control de los procesos. Esto quiere decir, que el diagnóstico de los procesos se hace manualmente a través de estos gráficos, y requiere de personal especializado para identificar correctamente patrones relacionados en ellos. Por lo tanto, el proceso de monitoreo está sujeto a inexactitudes o desviaciones al momento del analizar el gráfico.

Con el objetivo de mitigar esta situación, modelos autónomos para clasificar patrones, presentan características que llevan a cabo la posibilidad de su aplicación en gráficos de control. Desarrollar un modelo de este tipo, implica librarse de las fallas efectuadas por el personal, así como imprecisiones y sesgos.

Para presentar el funcionamiento de un modelo de reconocimiento de patrones en gráficos de control, se hace relevante evaluar el sistema mediante información de un proceso real. Por esto, una empresa del sector azucarero facilita la información pertinente para efectuar la evaluación, obtener resultados y realizar los análisis adecuados.

2 JUSTIFICACIÓN

Actualmente interpretar los gráficos de control, se ha convertido en una labor con alto grado de subjetividad por la heurística utilizada, con el fin de entender las características de los patrones en estos gráficos.

Hoy en día, las compañías con la tendencia hacia un mundo globalizado, debe reforzar sus tecnologías a través de herramientas que permitan mayor flexibilidad en los procesos de calidad. Por esto, se hace relevante la búsqueda de nuevas alternativas para resolver los inconvenientes presentados en la interpretación de los gráficos de control, como inexactitudes o desviaciones efectuadas por los especialistas en la ocupación. Del mismo modo, cubrir la necesidad de evitar la interpretación errónea de estos gráficos, adquiere gran importancia en la toma de decisiones respecto a la conformidad de los productos.

Debido a la alta competitividad, las empresas en la actualidad y teniendo en cuenta la capacidad de sus procesos productivos, no pueden dejar escapar recursos que no generan rentabilidad, además de esto, la calidad de sus productos representan participación en el mercado; por lo anterior es inadmisibles errores en cuanto a la calidad de la producción, y el control estadístico de procesos representa una fuerte herramienta para mantener los estándares establecidos.

Entonces, implementar un sistema capaz de reconocer patrones en los gráficos de control con asertividad y eficiencia, carente de desviaciones, sesgos o imprecisiones, capaz de determinar si los procesos conservan el comportamiento esperado o están siendo afectados por causas asignables, representa un mecanismo del cual se puede sacar el mayor provecho, agilizando el análisis de las causas, y ayudando así a la toma de decisiones en cuanto a la conformidad de los productos y ajustes de los procesos.

Del mismo modo, los beneficios de la herramienta, se ven reflejados en ahorro de tiempo, personal y errores humanos, en las organizaciones que direccionan sus esfuerzos a la producción, usando la calidad como fuente generadora de valor.

Por otro lado, sin el desarrollo de esta técnica, los fallos humanos en la interpretación de los gráficos de control pueden seguir generándose, afectando la conformidad de los productos, produciendo costos de no calidad e incurriendo en reprocesos (Prat, Tort-Martorrel, Grima, & Pozueta, 1998).

3 OBJETIVOS

OBJETIVO GENERAL

Implementar una herramienta de reconocimiento de patrones en cartas de control univariadas, para la toma de decisiones en el control estadístico de procesos

OBJETIVOS ESPECÍFICOS

- Identificar cartas de control y sus patrones comúnmente presentados
- Identificar herramientas para el reconocimiento de patrones en cartas de control
- Implementar una herramienta que clasifique patrones en cartas de control univariadas
- Validar el funcionamiento de la herramienta mediante un caso de estudio con un proceso bajo observación en un Ingenio Azucarero en el Norte del Valle.

4 MARCO REFERENCIAL

En este apartado se aborda de manera general la descripción de los gráficos de control, y se detallan los patrones básicos que se presentan comúnmente en estos gráficos según (Western-Electric, 1956), (Bhattacharyya & Chakraborty, 2009), (Yang J. , 2009) y (Addeh, Ebrahimzadeh, & Ranaee, 2011); además, se hace una revisión de las herramientas más utilizadas que se enfocan a identificar estos patrones.

4.1 GRAFICOS DE CONTROL

El control estadístico de procesos, ha sido un tema de recurrente investigación, donde se abordan aspectos relacionados desde la construcción de los gráficos de control, su interpretación, hasta la identificación de patrones no aleatorios que se presentan en los procesos. Es una herramienta que contribuye ostensiblemente a mantener la calidad de los productos, en cuanto a sus especificaciones según estándares establecidos. Así, los gráficos de control han tomado lugar en diferentes industrias, convirtiéndose en herramienta de fundamental aplicación, con el objetivo de revelar inconformidades en los procesos.


En general, un gráfico de control es una representación en el cual se manifiesta la calidad de las características de los productos, a través del tiempo. Estos gráficos, se componen de una línea central que representa el valor medio de la característica de calidad correspondiente. Otras dos líneas a una distancia de tres desviaciones típicas, componen el gráfico de control básico, de modo que la mayoría de las muestras suministradas caerán dentro de ellas (Prat, Tort-Martorrel, Grima, & Pozueta, 1998).

El desarrollo de estos gráficos está directamente relacionado con su interpretación, así lo evidencia *Statistical quality control handbook* (Manual de control estadístico de calidad), el cual fue elaborado con el objetivo de explicar el manejo del control de la calidad en términos estadísticos. En este documento se tiene en cuenta la elaboración de los gráficos de control, los tipos de gráficos más utilizados y los parámetros que se deben considerar para elaborar correctamente los diagramas. La interpretación de estos gráficos, es uno de los asuntos más importantes para esta investigación que presenta el manual. Se presentan quince patrones evidenciados en los gráficos de control, cada uno con su descripción y sus particulares causas de variación (Western-Electric, 1956).

Montgomery, 1992 presenta la estructura y funcionalidad de los gráficos de control, así como sus patrones de inestabilidad usualmente evidenciados. En su libro *Introduction to statistical quality control*, se describen siete patrones no aleatorios y sus causas de variación.

Tomando en cuenta las posturas que presentan (Western-Electric, 1956) y (Montgomery, 1992) respecto al comportamiento que presentan los procesos mediante los gráficos de control, los patrones a tomar en consideración en este estudio se presentan en la Figura 1.

Figura 1 Patrones presentados en gráficos de control



Fuente: (Gauri & Chakraborty, 2006)

4.1.1 Interpretación de gráficos de control

El objetivo de la utilización de los gráficos de control para el seguimiento de un proceso, es primordialmente el de detectar cualquier evidencia de que la media y la variabilidad del proceso no se han mantenido constantes a lo largo del tiempo. Es decir, se pretende detectar la aparición de causas asignables de variabilidad (Prat, Tort-Martorel, Grima, & Pozueta, 1998).

La interpretación de estos gráficos, generalmente es realizada por personas, las cuales evalúan manualmente si los procesos están cumpliendo las especificaciones requeridas. Esto quiere, decir que los gráficos son desarrollados de forma manual y asimismo su interpretación. La subjetividad de las personas encargadas de esta labor juega un papel importante para la correcta interpretación del estado de los procesos, así como para la toma de decisiones.

Estos gráficos muestran donde el proceso está centrado, es decir, que representa la posición del promedio de la distribución del proceso en un momento dado. Si el promedio del proceso cambia, en el gráfico se evidencia la misma tendencia. De allí parten los patrones presentados en la Figura 1 (Western-Electric, 1956).

Los patrones involucrados en este estudio y sus causas de variación toman importancia para toma de decisiones sobre los procesos y su descripción se detalla a continuación:

- **Normal:** Este patrón no es representativo de variaciones no naturales de los procesos, por lo cual se espera que la producción sea conforme a los requerimientos establecidos.
- **Tendencia:** La tendencia, ya sea hacia arriba o hacia abajo, es un movimiento gradual continuo en una dirección. Este tipo de patrón se concibe debido al deterioro gradual de los componentes críticos del proceso o equipo. También, la fatiga en los operadores es una causa de esta variación, además de la temperatura, la cual muchas veces es una causa que afecta la calidad de los productos ostensiblemente, y puede ser eliminada.
- **Cambio:** Los cambios en la media, se pueden presentar debido a alteraciones en el método de trabajo, en materiales, operadores e incluso por cambios en los métodos de inspección. También se ve reflejado este patrón, por la motivación o atención del personal.
- **Ciclo:** Este cambio puede ser generado por cambios sistemáticos en el medio ambiente como temperatura, la rotación regular de las máquinas u operadores, variables como presión o tensión afectan la máquina manifestando este comportamiento en los gráficos. También los programas de mantenimiento y desgaste de piezas afectan el proceso de esta manera (Montgomery, 1992).

Algunas herramientas se han utilizado para identificar estos patrones con buen nivel eficiencia y de asertividad.

4.2 MAQUINAS DE SOPORTE VECTORIAL (SVM)

El desarrollo de las Máquinas de Soporte Vectorial (SVM por sus siglas en inglés), es relativamente nuevo; algoritmos para esta herramienta fueron desarrollados a mediados de la década de los 90's por (Cortes & Vladimir, 1995) y han sido utilizados para tareas de reconocimiento.

Du, Huang, & Lv, 2013 proponen un sistema basado en SVM para clasificar los seis patrones básicos en gráficos de control, además de combinaciones entre estos. Los parámetros del modelo son optimizados con la técnica *Particle Swarm Optimizacion* para mejorar la eficiencia del clasificador, mostrando eficiencia relativamente alta.

En la práctica es posible adaptar este tipo de técnicas en la producción de bienes. La aplicación de un modelo basado en SVM es utilizado para identificar catorce patrones en los gráficos de control -incluyendo patrones simples y combinaciones entre estos- en un proceso de fabricación de celulares. Los resultados de la investigación muestran que el sistema es sobresaliente al presentar un alto rendimiento (Wu, 2011).

En control estadístico de procesos, esta herramienta ha sido explotada con favorable desempeño para clasificar patrones en gráficos de control. *Application of the PSO-SVM model for recognition of control chart patterns*, es una publicación destinada a identificar seis patrones básicos evidenciados en los gráficos de control, en la cual se optimizan los parámetros del modelo con la técnica *Particle Swarm Optimization*, lo cual juega un papel importante en el rendimiento del sistema (Ebrahimzadeh, Ranaee, & Ghaderi, 2010).

Otras aplicaciones del SVM direccionadas al control estadístico de procesos, son realizadas por (Ranaee & Ebrahimzadeh, 2011) y (Das & Banerjee, 2010), donde desarrollan sistemas de optimización basado *Algoritmos genéticos*, para aumentar el rendimiento del clasificador, a través de la búsqueda de la mejor combinación de sus parámetros. El rendimiento del SVM presenta un desempeño considerablemente alto en comparación con otras herramientas de clasificación.

Esta herramienta también es utilizada para clasificar mezclas de patrones en gráficos de control. Lu, Shao, Li, & Wang, 2010 desarrollan un modelo de reconocimiento basado en SVM, identificando combinación de cinco patrones relacionados en los gráficos de control. En el estudio se utiliza análisis de componentes independientes obtener eficientemente los datos de entrada al sistema.

Yang J., 2009, utiliza análisis de componentes principales para eliminar información redundante y reducir el tamaño de los datos de entrada un modelo de clasificación basado en SVM. Este proceso es un método estadístico que centra la información dispersa en un conjunto de variables, con el objetivo de examinar el comportamiento del modelo con procesamiento de datos.

Esta herramienta ha tomado relevancia entre investigadores que dedican sus esfuerzos al reconocimiento de patrones en gráficos de control, ya que ha sido un método que presenta características favorables en tareas de clasificación.

4.3 ARBOLES DE DECISIÓN (DT)

Los *árboles de decisión* (DT por sus siglas en inglés), es una técnica basada en la construcción de diagramas lógicos, que sirve para categorizar una serie de condiciones en series sucesivas. Esta herramienta tiene múltiples aplicaciones, entre estas, la clasificación de patrones en gráficos de control específicamente.

A hybrid approach for identification of concurrent control chart patterns, es una publicación de 2008, la cual propone diferenciar cada patrón presentado en una mezcla de tendencias, cambios o ciclos en los gráficos de control. En la aplicación del sistema, se hace un *análisis de componentes independientes*, para encontrar una buena representación en el conjunto de datos de entrada al clasificador; mientras que la lógica del DT se realiza utilizando indicadores estadísticos como nodos en el árbol, para elegir los patrones correctos (Wang, Dong, & Kuo, 2008).

También el desarrollo de (Kumar & Chakraborty, 2006) expresa la posibilidad del uso de un árbol de decisión para clasificar ocho patrones presentados en los gráficos de control. El desarrollo de este estudio contiene treinta y dos características diseñadas para estructurar el árbol de decisión. El modelo resultante muestra un árbol con 21 nodos para reconocer ocho clases de patrones y los resultados son satisfactorios con buen desempeño.

Esta herramienta puede presentar sencillez en su modelo, pero la consistencia de los resultados no es muy alta, lo que provoca confusiones al buscar las causas de variación. Además, su practicidad es muy poca en la aplicación de casos reales por el tratamiento que se le debe dar a los datos.

4.4 REDES NEURONALES ARTIFICIALES (ANN)

Las redes neuronales artificiales (ANN por sus siglas en inglés) es una herramienta que intenta emular las propiedades básicas de las redes neuronales biológicas, con características especiales de las cuales se destaca el reconocimiento de patrones.

Por la capacidad de generalización de esta herramienta se convierte en un poderoso clasificador según (Anagun, 1998). Su aparición yace desde mediados del siglo XX cuando se publica *A logical calculus of the ideas immanent in nervous activity* por (McCulloch & Pitts, 1943). Desde entonces, se viene desarrollando múltiples aplicaciones para esta herramienta en diferentes campos de la investigación.

La primera publicación realizada sobre el empleo de redes neuronales en los gráficos de control según (Zorriassatine & Tannock, 1998), fue *Synthetic neural networks for process control*, desarrollada por (Pugh, 1989). Desde ese momento,

investigadores han enfocado sus esfuerzos en mejorar la precisión de esta herramienta en la clasificación de patrones en estos gráficos.

Una de las estructuras de las redes neuronales más utilizadas en tareas de clasificación es el *Perceptrón*, desarrollado por (Rosenblatt, 1962) que utiliza (Gutiérrez, Vásquez, Hernández, Hernández, & López, 2012) para identificar cambios en la media de una variable de interés, en el procesamiento de un producto alimenticio. Esta aplicación señala la posibilidad del empleo de esta herramienta en casos prácticos.

En el *Perceptrón*, los algoritmos de entrenamiento son una de las variantes más importantes. Estos tienen fuerte incidencia en el rendimiento de la ANN, y el algoritmo *Backpropagation* –desarrollado por (Rumelhart & Hinton, 1986)- es fuertemente empleado en tareas de clasificación; así lo demuestran las publicaciones de (Guh & Hsieh, 1999), (Yu, Xi, & Wu, 2007), (Masood & Hassan, 2008), (Bhattacharyya & Chakraborty, 2009) y (Ghiasabadi, Noorossana, & Saghaei, 2013) que ejecutan su investigación basados en este algoritmo, el cual finalmente permite obtener resultados satisfactorios en la precisión del modelo.

Otro tipo de ANN utilizada para clasificar patrones en los gráficos de control son las *Recurrentes*³. *Systematic Study to Assess Neural Networks' Capability in Classifying Control Chart Patterns*, es un artículo en el que se propone comparar entre redes Recurrentes y Feedforward⁴ - , confrontando diferentes clases de algoritmos de entrenamiento para analizar su desempeño. Finalmente las redes *Recurrentes* presentan mejor rendimiento, proveyendo una alternativa además del *Perceptrón*, para las tareas de clasificación de patrones en gráficos de control (Lavangnananda & Kasikitsakulphol, 2010).

Las ANN's de *Función de Base Radial*⁵ (RBF por sus siglas en inglés), han tenido aplicaciones para identificar patrones en los gráficos de control. Ebrahimzadeh & Ranaee, 2009 presentan en la publicación *A Hybrid Intelligent Technique for Recognition of Control Chart Patterns*, la utilización de esta tipo de redes enfocadas al control estadístico de procesos, para identificar seis patrones en gráficos de control conservando alto nivel de rendimiento, al optimizar previamente parámetros en la red.

También el *Aprendizaje de Cuantificación Vectorial*⁶ (LVQ por sus siglas en inglés), es otra alternativa que proveen las ANN's dirigidas hacia el reconocimiento de patrones en gráficos de control. *Recognition of unnatural patterns in process*

³ En este tipo de red sus conexiones están enlazadas con neuronas de la capa siguiente, anterior y con unidades de la misma capa (Lavangnananda & Kasikitsakulphol, 2010).

⁴ Son redes neuronales que propagan su información en un único sentido (Del Brío & Sanz, 2002)

⁵ Las redes RBF se caracterizan por solo tener dos capas y utilizar una función Gaussiana para activar las neuronas.

⁶ En esta red el tipo de aprendizaje es competitivo entre neuronas.

control charts through combining two types, es un sistema integrado por la combinación de las redes LVQ y Perceptron, que componen dos módulos para clasificar tanto patrones de inestabilidad individuales como simultáneos. En publicaciones como ésta, se demuestra la evolución de las ANN's en aplicaciones enfocadas al control estadístico de procesos, al identificar mezcla de patrones no aleatorios en gráficos de control (Fatemi, Lesany, & Koochakzadehc, 2011).

Ebrahimzadeh & Ranaee, 2010 y (Addeh, Ebrahimzadeh, Azarbad, & Ranaee, 2013) emplean los algoritmos de optimización PSO y Cuco respectivamente para optimizar los parámetros y mejorar el diseño de su correspondiente modelo. Estos algoritmos permiten que los parámetros sean más apropiados al modelo y permitan mejor rendimiento.

El tratamiento que se da a los datos de entrada a los sistemas de clasificación, tiene cierto nivel de influencia en su rendimiento final. Guh & Hsieh, 1999 y (Bhattacharyya & Chakraborty, 2009) utilizan la información generada mediante simulación Montecarlo como fuente de suministro para la red; mientras (Hassan, Shariff, Shaaroun, & Jamaluddin, 2003), (Hassan, Shariff, Shaaroun, & Jamaluddin, 2003) y (Addeh, Ebrahimzadeh, & Ranaee, 2011) extraen ciertas características estadísticas de los datos simulados –como media cuadrática, media, desviación estándar, cusum, autocorrelación y sesgo- para representar los patrones que se evidencian en los gráficos de control, mejorando el rendimiento final de la red mediante el procesamiento de las entradas al sistema.

En la publicación de (Shao, Lin, & Chan, 2011) se usa el análisis de componentes independientes, con el fin de mejorar la relevancia de las entradas y asimismo el rendimiento de una red neuronal, destinada a identificar mezcla de patrones.

El artículo de (Kumar & Chakraborty, 2008) utiliza como entrada a la red algunos coeficientes desarrollados por (Gauri & Chakraborty, 2006) y son tomados de la generación de patrones para alimentar una red neuronal. Siete coeficientes son tomados en cuenta para ingresar al sistema y son elegidos mediante un análisis de correlación.

4.5 SINTESIS

Debido a la globalización y la alta competitividad que se evidencia hoy en día a nivel mundial, muchos expertos han direccionado sus esfuerzos hacia el mejoramiento de la calidad utilizando técnicas que contribuyan a mejorar los productos, reduciendo de esta manera costos de todo tipo. Los investigadores en el campo del control estadístico de procesos, han entendido la posibilidad de aplicar herramientas inteligentes para el reconocimiento de patrones en los gráficos de control. Por lo tanto, se han empleado diferentes técnicas para clasificar patrones de inestabilidad en estos gráficos.

Los sistemas basados en ANN, SVM y DT son fuertemente utilizados en el reconocimiento de estos patrones. Su desempeño es influenciado por dos variables principalmente: los parámetros del clasificador y los datos de entrada al sistema.

El tratamiento que se da a las entradas es fundamental para fortalecer el rendimiento de este tipo de sistemas. Las publicaciones presentan el progreso en el desempeño de estas herramientas con eficiente determinación de los datos de entrada. Con este objetivo, es útil tener en cuenta varias técnicas estadísticas para determinar la mejor combinación de datos, y del mismo modo ayudar a mejorar la estructura del modelo y su facilidad de computación.

En algunas de las publicaciones del apartado anterior se observa el uso de técnicas de optimización altamente poderosas, que son apoyo fundamental para las herramientas de reconocimiento de patrones. Según estas publicaciones, el rendimiento del clasificador se ve fuertemente influenciado por los parámetros utilizados en el sistema, así como por los datos de entrada al clasificador. También se demuestra que estas técnicas pueden ser aplicadas en casos prácticos con buen desempeño.

Entre los artículos mostrados existe una similitud que radica en la generación de los datos de entrada a los sistemas. Debido a la cantidad de patrones necesarios, los investigadores utilizan simulación Montecarlo para producir la cantidad de información necesaria de entrada a los sistemas. Esta simulación se hace teniendo en cuenta una distribución Normal $N(0,1)$ lo cual valida la representación de la información de entrada con datos de casos reales (Yang J. , 2009), (Gauri & Chakraborty, 2007), (Hassan, Shariff, Shaaroun, & Jamaluddin, 2003).

5 SELECCIÓN DEL CLASIFICADOR

A continuación se presenta la argumentación tomada en consideración, para seleccionar la herramienta de mayor conveniencia para este estudio.

5.1 SELECCIÓN DE LA HERRAMIENTA

Partiendo de la revisión bibliográfica realizada en el capítulo anterior, se han contemplado las diferentes herramientas utilizadas para el reconocimiento de patrones en gráficos de control por la comunidad científica. Estas tres herramientas, redes neuronales artificiales (ANN's), máquinas de soporte vectorial (SVM) y árboles de decisión (DT), según investigadores son válidas para clasificar este tipo de patrones; por lo tanto se toma en cuenta los siguientes criterios para seleccionar la mejor opción:

- Cantidad de aplicaciones de la herramienta
- Precisión o rendimiento del sistema
- Tiempo de computación
- Facilidad de aplicación en ambientes laborales
- Variedad de alternativas

Al considerar estos 5 factores se analiza lo siguiente:

Al considerar el capítulo anterior, la tendencia que hoy en día toman las investigaciones hacia la interpretación de los gráficos de control, antepone a las ANN's sobre otras herramientas. Esto quiere decir que la aceptación de este método para clasificar patrones en gráficos de control, es sumamente válido, ya que sus cualidades han inclinado a la mayoría de los autores presentados en este estudio, a enfocar sus esfuerzos en la aplicación de este recurso, incluso además del campo de investigación, se han hecho aplicaciones en el sector industrial.

Uno de los factores más importantes que se tiene en cuenta al desarrollar este tipo de modelos automáticos, es la precisión o rendimiento del sistema. Esto representa la capacidad del modelo para producir un resultado inequívoco de las características de un vector previamente ingresado. Tal vez, mejorar el rendimiento del sistema es una de las labores que conlleva mayor análisis en su desarrollo, y uno de los factores a los que apuntan los investigadores en la aplicación de este tipo de herramientas. De allí, que el progreso de ANN's con el tiempo han mejorado en cuanto al empleo de sus parámetros, y asimismo su rendimiento. Por esto las ANN's en cada una de sus aplicaciones muestran resultados con precisión altamente satisfactoria, y consistencia en la tarea de clasificación.

El tiempo de computación y memoria requerida para desarrollar un modelo de clasificación, son aspectos para tener en cuenta al momento de seleccionar una herramienta de este tipo. Estos requerimientos desvían la atención sobre las ANN's, debido a que dentro de algunos de sus modelos, la rapidez de convergencia y eficiente computación, son las características más destacables.

El manejo de información de entrada al sistema, también es un aspecto a tomar en cuenta en esta clase de modelos, ya que en el entorno laboral es necesaria la sencillez y el manejo práctico de datos, para la eficiente toma de decisiones. El manejo de las entradas a un modelo basado en ANN's es sumamente sencillo, debido a que solo es indispensable ingresar vectores con las características suficientes que presentan los patrones en los gráficos de control, tanto para el entrenamiento del modelo como para evaluar un proceso real.

Una de las grandes ventajas de las ANN's, es su diversidad de alternativas para estructurar un sistema de reconocimiento de patrones en gráficos de control. Investigaciones acerca de la aplicación de distintos métodos que han sido objeto de estudio por diversos investigadores, arrojan que el desempeño de los diferentes modelos es relativamente alto. Además, la variedad de este tipo de modelos, proporcionan una buena cantidad de alternativas para su configuración, teniendo en cuenta las necesidades del estudio.

Los modelos basados en ANN's aplicados al control estadístico de procesos, se exponen en el siguiente apartado.

5.2 SELECCIÓN DEL MODELO


Al seleccionar las ANN's como herramienta para clasificar patrones en los gráficos de control, el paso siguiente es elegir cuál es el tipo de modelo basado en ANN's más conveniente para su aplicación en este estudio.

Con relación a la revisión bibliográfica expuesta anteriormente, se elabora una matriz de comparación autor- modelo (presentada en el anexo 1), para identificar el modelo más utilizado en la clasificación de patrones en gráficos de control. Los resultados de la matriz de comparación se presentan en la figura 1.

En el siguiente esquema se presentan ocho modelos utilizados para el reconocimiento de patrones en gráficos de control, relacionados en dieciséis artículos, y desarrollados por treinta y dos investigadores que han dedicado sus esfuerzos al uso de ANN's en control estadístico de procesos. Es evidente que en la gráfica, el modelo Multilayer perceptrón (MLP) abarca la mayor proporción de investigaciones, lo cual indica su idoneidad para este tipo de tareas. Los otros modelos también utilizados en distintas investigaciones son: Learning Vector Quantization (LVQ), Radial Basis Function (RBF), Probabilistic Neural Network, Elman Backpropagation Network (ELM), Layer Recurrent Networks (LRN),

Nonlinear Autorregressive Network With Exogenous Inputs (NARX) y un sistema híbrido que basado en los modelos Learning Vector Quantization y Multilayer Perceptrón relacionados en la gráfica.

Figura 2. Resultados matriz de comparación autor-modelo



Fuente: Elaboración propia

De los estudios investigados, se puede concluir que algunas de las ventajas más importantes que ofrece el modelo MLP son:

- Su computación es relativamente fácil, debido a la poca complejidad del sistema
- Es suficientemente flexible como para reconocer diferentes tipos de patrones
- Tiene alto nivel de precisión en sus aplicaciones
- El tiempo de computación del sistema es reducido.

Al ser el modelo MLP aceptado y ampliamente utilizado por la comunidad científica, y teniendo en cuenta sus ventajas ofrecidas, se hace relevante la utilización de este tipo de modelo para clasificar patrones en los gráficos de control en la presente investigación.

6 ¿QUE SON LAS REDES NEURONALES ARTIFICIALES (ANN's)?

Las ANN's son el resultado de los intentos por reproducir mediante computadoras el funcionamiento del cerebro humano (ver tabla 1). Los modelos de ANN's hasta hoy en día se caracterizan por su simpleza y lo que se busca no es imitar a las neuronas auténticas, sino lograr una máquina de computación en paralelo formada por la interconexión de muchos elementos simples de cálculo (Del Brío & Sanz, 2002).

Tabla 1. Cerebro frente a computador convencional

	Cerebro	Computador
Velocidad de proceso	10^{-2} seg. (100 Hz)	10^{-9} seg. (1000 MHz)
Estilo de procesamiento	Paralelo	Secuencial
Número de procesadores	$10^{11} - 10^{14}$	Pocos
Conexiones	10.000 por procesador	Pocas
Almacenamiento del conocimiento	Distribuido	Direcciones fijas
Tolerancia a fallos	Amplia	Nula
Tipo de control del proceso	Auto-organizado	Centralizado

Fuente: (Del Brío & Sanz, 2002)

Actualmente, salvo en operaciones simples de cálculo aritmético, el cerebro humano es superior a cualquier ordenador. Las principales características del cerebro son su robustez y paralelismo masivo, ya que su funcionamiento no se ve alterado ante cambios de pequeña importancia, y gracias a su flexibilidad, se adapta con rapidez a entornos cambiantes, además de tratar con información ambigua o incompleta. Por lo tanto, la propiedad del cerebro humano más buscada a través de las ANN's, es la capacidad de aprender de la experiencia y generalizar a partir de ella (Santín, 2003).

6.1 HISTORIA DE LAS ANN'S

La historia de las redes neuronales artificiales, comienza con el descubrimiento del científico Aragonés Santiago Ramón y Cajal, descubridor de la estructura del sistema neuronal del ser humano. A principios del siglo XX en su obra *Textura*, expone una particular y hasta ahora válida concepción acerca del sistema nervioso, la cual cita que el sistema nervioso del ser humano está conformado por una red de células altamente interconectadas entre sí, contradiciendo así la teoría reticularista, que sostenía que el sistema nervioso estaba estructurado por una red continua de fibras nerviosas. Pero Ramón y Cajal, va más allá de descubrir la estructura del sistema nervioso, demostrando también como fluye la información desde las dendritas, pasando por el soma y llegando hasta el axón. Por estos descubrimientos se hace merecedor del premio Nobel de medicina en 1906 (Del Brío & Sanz, 2002).

Fundamentados es esta teoría, en 1943 un neurofisiólogo y un matemático, Warren McCulloch y Walter Pitts respectivamente, publican *A logical calculus of the ideas immanent in nervous activity*, donde lanzan la teoría sobre la forma de trabajo de las neuronas, tomando como premisa que una neurona es “*todo o nada*” como una característica de la actividad nerviosa, es decir, que las neuronas se activan o no en el sistema nervioso, desarrollando así el primer modelo de una neurona artificial (McCulloch & Pitts, 1943). Desde allí, se da el punto de partida para el desarrollo de diferentes modelos y algoritmos de aprendizaje:


- En 1949, el fisiólogo Donald Hebb expuso en su libro *The Organization of Behavior* la conocida regla de aprendizaje. Su trabajo tenía que ver con la conductividad de la sinapsis, es decir, con las conexiones entre neuronas.
- En 1957, Frank Rosenblatt presentó al *Perceptrón*, una red neuronal con aprendizaje supervisado cuya regla de aprendizaje era una regla planteada por Hebb.
- En 1969 Marvin, Minsky y Seymour Paper, escribieron un libro llamado *Perceptrons*, en donde definían a estos como caminos sin salida.
- En los años 60 se propusieron otros dos modelos también supervisados, basados en el *Perceptrón* de Rosenblatt denominados *Adaline* y *Madaline*. En estos, la adaptación de los pesos se realiza teniendo en cuenta el error, calculando como la diferencia entre la salida deseada y la dada por la red, al igual que en el *Perceptrón*.
- En los década de los 70's las redes neuronales artificiales surge con la técnica de aprendizaje de propagación hacia atrás o *Backpropagation*.
- En 1977, James Anderson desarrolló un modelo lineal, llamado asociador lineal, que consistía en unos elementos integradores lineales (neuronas) que sumaban sus entradas.
- En 1982 John Hopfield presentó un trabajo sobre redes neuronales en la Academia Nacional de las Ciencias, en el cual describe con claridad y rigor matemático una red a la que ha dado su nombre que viene a ser una variación del *Asociador Lineal*. En este mismo año la compañía Fujitsu comenzó el desarrollo de computadores pensantes para aplicaciones relacionadas con la Robótica (Varela & Campbells, 2011).

De este modo, las redes neuronales artificiales son modelos matemáticos que intentan reproducir el comportamiento del cerebro humano, emulando algunas de sus características más relevantes.

6.2 REDES NEURONALES BIOLÓGICAS

En el cerebro humano hay alrededor de cien mil millones (10^{11}) de neuronas interconectadas. Su especial forma de trabajo, las convierte en el sistema más versátil y eficaz para procesar información procedente del mundo real. En la figura 2 se esquematiza una neurona biológica. Cada neurona tiene un cuerpo celular o soma que a la vez contiene un núcleo celular. A partir del cuerpo de la neurona, se ramifica una cantidad de fibras llamadas dendritas, y su función es captar la información enviada desde otras neuronas por impulsos, ya sea por proceso químico o choques eléctricos. Desde el cuerpo celular, también se desprende una fibra tubular denominada axón, que se encarga de transmitir la información procesada a otras neuronas, y que a su vez se divide en ramificaciones axiales para encontrar las uniones sinápticas. Una neurona se conecta con entre cien y cien mil neuronas formando una robusta sinapsis⁷. Se estima que hay unas 10^{14} sinapsis en el cerebro de un adulto (Sarraute, 2007).

Figura 3. Neurona biológica



Fuente: (Del Brío & Sanz, 2002)

Aún se desconoce mucho sobre la forma en que el cerebro aprende a procesar la información, en la actualidad las teorías hablan sobre el efecto del aprendizaje resulta de la modificación de las conexiones o sinapsis entre neuronas. Este mecanismo de modificación de los pesos sinápticos se produce en el tiempo por medio de la experiencia del sujeto y se realiza aumentando o disminuyendo el número de neurotransmisores liberados en determinadas sinapsis ante un mismo estímulo. Así, una neurona cuyo potencial antes no lograba alcanzar el umbral, ahora sí lo hace y se activa, y viceversa, otra que antes se activaba ahora puede que no lo haga y así la respuesta que el individuo da ante una misma situación real sea bien distinta, decimos entonces que hemos aprendido. Normalmente el

⁷Relación funcional de contacto entre las terminaciones de las células nerviosas (Real Academia Española).

aprendizaje requiere además de un maestro que indique como realizar bien una tarea. Tras un proceso de ensayo-error el individuo es capaz de realizar correctamente una tarea que antes no era capaz de resolver (Santín, 2003).


6.3 FUNDAMENTOS DE LAS ANN'S

Bajo la descripción de que la búsqueda de las ANN's es aprender de la experiencia y generalizar a partir de ella, tratar de simular este complicado proceso biológico, es realizado en base al siguiente modelo:

- La información se procesa en elementos simples llamados neuronas, nodos o unidades de procesamiento en la literatura.
- Las señales de entrada o *inputs*, X_i , $i = 1, 2, \dots, n$; se transmiten entre las neuronas a través de conexiones.
- Cada conexión tiene asociado un peso W_{ij} , que representa la intensidad de la señal recibida correspondiente al *input* i en la neurona j . La mayor o menor intensidad de cada entrada representa la influencia del mismo en el resultado final.
- Cada neurona j suma todas las señales recibidas, $\sum W_{ij} * X_i$ procedentes de otras neuronas y las transforma mediante una función de activación, generalmente no lineal, para determinar la señal de salida *output*, que transmite a otras neuronas, donde el proceso se repite. Finalmente, tras la interacción de las neuronas que componen la red, la señal o respuesta de la red se transmite al exterior.
- Generalmente, se añade al conjunto de pesos de la neurona un parámetro adicional θ_i , nombrado umbral, que resta el potencial postsináptico y representa el límite de activación de la neurona, es decir el nivel mínimo que debe alcanzar el potencial postsináptico para que la neurona se dispare.
- El aprendizaje se realiza mediante el ajuste de los pesos que ponderan las conexiones entre las neuronas que componen la red. El algoritmo de aprendizaje es el método por el que se obtienen los ajustes óptimos evitando tener que supervisar todo el proceso. Este método consta de una serie de pasos sencillos e iterativos.
- Para procesar la información, las neuronas se organizan en capas: la capa de entrada transmite las variables de entrada *inputs* utilizadas, la capa de salida presenta el *output* final y entre ellas pueden existir una o más capas ocultas que procesan la información.

En definitiva, se puede definir una red neuronal como un conjunto de procesadores sencillos, organizados en capas y altamente interconectados, que son capaces de aprender y generalizar la relación desconocida entre varias variables a partir de ejemplos reales. El objetivo de la red es, por tanto, aprender a asociar un vector *input*, X , a un vector *output*, Y , a partir de la interacción entre las neuronas, W (Santín, 2003). Gráficamente la estructura de una neurona artificial se expresa como en la figura 3.

Figura 4. Modelo de neurona artificial



Fuente: (Del Brío & Sanz, 2002)

6.4 CARACTERISTICAS DE LAS ANN'S

A continuación se exponen algunas propiedades características de las ANN's, que se debe tener en cuenta para entender mejor su aplicabilidad.

6.4.1 Arquitectura de las ANN's

Como se ha mencionado anteriormente, la estructura de las ANN's se encuentran organizadas en distintas capas:

- **Capa de entrada:** Recibe la información del exterior. Esta capa generalmente no procesa señales recibidas, sino que envía la información a la siguiente capa. El número de neuronas en esta capa depende del problema específico en consideración. Desde el punto de vista de los gráficos de control, las muestras de los patrones comprenden las *inputs* que se presentarían en la capa de entrada.
- **Capa(s) oculta(s):** Las neuronas de esta capa reciben señales desde las *inputs* u otras capas ocultas, para procesar la información recibida y

enviarla a la siguiente capa oculta o a las *outputs*. Muchos de los problemas dedicados al reconocimiento de patrones utilizan redes con solo una capa oculta. De la modificación de los pesos de esta neurona depende el aprendizaje de la red.

- **Capa de salida:** Esta capa recibe las señales de la capa oculta, para transformar la información y enviar la respuesta al exterior. Generalmente en los gráficos de control, las salidas de esta capa se ejecutan de forma binaria y corresponden al número de patrones a clasificar.

6.4.2 Propiedades de las ANN's

Debido a sus fundamentos, las ANN's muestran gran cantidad de propiedades similares a las del cerebro humano, entre las cuales se pueden mencionar la capacidad de aprehensión a partir de la experiencia, poder de generalización, entre otras. Algunas de las características más importantes son:

- **Procesamiento paralelo:** Respecto a esta particularidad, se puede hacer un comparativo con los computadores convencionales basados en la estructura Von Neumann. Estos están conformados por una unidad de entrada, una de procesamiento y una de salida, las cuales se estructuran secuencialmente siendo capaz de ejecutar series de instrucciones complejas, y tareas de alto nivel como razonamiento y cálculos. A diferencia de las máquinas Von Neumann, las ANN's tienen una unidad de procesamiento demasiado simple, radicando su poder en la funcionalidad paralela de múltiples neuronas permitiendo procesar tareas de bajo nivel como reconocimiento de patrones, percepción, control, entre otros.
- **Memoria distribuida:** La memoria en los sistemas neuronales se encuentra distribuida por la sinapsis de la red, de modo que si alguna neurona sufre daños solo se afecta una parte de la información.
- **Aprendizaje adaptivo:** La capacidad de aprender a realizar tareas mediante un entrenamiento inicial, hace posible que las sinapsis de las neuronas se ajusten a condiciones dadas por el diseñador, generando su propia distribución de pesos, sin especificar a priori un modelo.
- **Auto-organización:** Las ANN's utilizan su poder de adaptación, para organizar la información recibida en el aprendizaje con el objetivo de cumplir un objetivo específico (Villanueva, 2002).

6.5 MODELO MULTILAYER PERCEPTRON (MLP)

Como se mencionó en el capítulo 6, el modelo *Multilayer Perceptrón* ha sido el de mayor utilización por los investigadores, y que en particular, será aplicado

posteriormente en esta investigación para el reconocimiento de patrones en gráficos de control.

Este tipo de modelo, generalmente es entrenado mediante el algoritmo denominado retropropagación de errores o *Backpropagation*, y tiene especiales características para abordar problemas de clasificación de gran envergadura, de una manera eficaz y relativamente simple según (Del Brío & Sanz, 2002).

6.5.1 Aprendizaje del MLP

Para la aplicación del MLP, existen tres fases a las que se debe enfrentar el modelo: La fase de entrenamiento, de validación y de test.

- **La fase de entrenamiento:** Radica en hacer que la red sea capaz de extraer, a partir de ejemplos, reglas generales que le permitan responder adecuadamente a patrones nunca antes visto. Este proceso consiste, por lo tanto, en la búsqueda de la matriz de pesos óptima.
- **La fase de validación:** Consiste en seleccionar cual de las redes, una vez entrenadas, responde mejor a los objetivos planteados.
- **La fase de test:** Una vez elegida la red que procesará las entradas, ésta será operativa, y es entonces cuando la arquitectura, número de neuronas, conexiones y pesos quedan fijos, y la red está lista para funcionar. En este momento se presenta a la red un patrón de entrada que nunca ha procesado con el fin de obtener una clasificación precisa e insesgada de los datos. Finalmente, una vez comparada la respuesta real y la estimada, se evalúa la eficiencia del MLP para resolver el problema planteado.

6.5.2 Funcionamiento del algoritmo *Backpropagation*

Para empezar el algoritmo de entrenamiento *Backpropagation*, es el método de aprendizaje supervisado, también conocido como regla delta generalizada (Rumelhart & McClelland, 1986). El objetivo del proceso de aprendizaje es ajustar los pesos de la red para que los patrones de entrada introducidos permitan obtener las salidas deseadas. El aprendizaje de tipo supervisado, se presenta a la red un conjunto de patrones, junto con la salida deseada u objetivo, e iterativamente se ajusta los pesos de la red hasta que su salida tiende a ser la deseada, utilizando para ello información detallada del error que comete en cada paso. Este proceso se lleva a cabo a través de la minimización de una función de actuación, que generalmente se corresponde con la suma de errores al cuadrado. El algoritmo *Backpropagation* consta de dos fases:

Fase 1: Propagación hacia adelante.

- 1. Inicialización:** Se asigna aleatoriamente a la red un vector de pesos uniformemente distribuidos cuyo rango depende del usuario.
- 2. Propagación:** Se presenta a la red un vector de entrada. Esta información se va propagando a través de todas las capas hasta obtener el vector salida global de la red.
- 3. Comprobación del error cometido:** A continuación la red compara la salida obtenida por ella con la deseada, conformando un error.

Una vez calculado el error, se tiene que determinar el sentido en que los pesos van a modificarse. Para ello se calcula el gradiente de la función de error, y de este modo los cambios en los pesos se deben producir en la dirección del contraria a la propagación de la red.

Fase 2: Hacia atrás

- 4. Adaptación del vector de pesos:** Los cambios en los pesos se producen en la dirección en la que el error caiga lo más rápidamente posible. Estas señales de error se propagan a los nodos de las capas, empezando por la de salida y siguiendo con las capas sucesivas. De esta forma, los nodos de cada capa sólo reciben una fracción del error global en función de su aproximada contribución relativa a la obtención de la salida.
- 5. Actualización de los pesos:** Los pesos se modifican con base en la señal de error recibida, de manera que se reduzca el error actual de la red y la salida obtenida se vaya aproximando a la deseada. Dentro de cada capa individual, el orden de actualización de los pesos no sigue un orden establecido
- 6. Vuelta al paso 2:** Con los nuevos pesos, se introduce un nuevo par de vectores *input-output*, y el proceso se repite hasta que el algoritmo converge cuando el error es suficientemente pequeño y se obtienen mejoras al seguir aplicando el algoritmo. Es entonces cuando el proceso de entrenamiento habrá finalizado.

Las principales desventajas de este algoritmo son que el tiempo de entrenamiento crece exponencialmente a medida que se incrementa el número de nodos en la capa oculta y que no existe ninguna seguridad ni forma de verificar que hemos alcanzado el mínimo global (Santín, 2003).

6.6 RECAPITULACIÓN: VENTAJAS Y DESVENTAJAS DE LAS ANN'S

Tras analizar el funcionamiento de las ANN's, es conveniente recapitular sobre las principales ventajas y desventajas de esta técnica.

- **Método de aprendizaje:** No necesitan ser programadas. Son capaces de extraer sus propias reglas a partir de ejemplos reales mediante la adaptación de la matriz de pesos. Esas reglas quedan almacenadas y extendidas a lo largo de las conexiones. Se dice que las ANN's no tienen memoria, sino que es un estado de la red que clasifica los patrones.
- **Tolerancia al ruido:** Son capaces de abstraer las características esenciales de los datos y de esta manera pueden generalizar correctamente, aún en presencia de datos incompletos o distorsionados.
- **No lineal:** Las ANN's permiten realizar a través de sus funciones de activación transformaciones no lineales de los datos, lo cual supone una ventaja frente a los métodos tradicionales de regresión y análisis discriminante múltiple.
- **Cantidad de datos suficiente:** Dado que la aplicación de las ANN's requieren el uso de tres submuestras de datos, la obtención de una base de datos lo suficientemente grande puede ser una limitación para su implementación práctica.
- **Caja no del todo negra:** La principal desventaja de las ANN's son, por un lado, la imposibilidad de determinar cómo se procesa internamente la información y, por otro, su incapacidad para contrastar estadísticamente si las entradas utilizadas son significativas. Aunque en la actualidad se han desarrollado modelos para inferir acerca de la influencia de cada variable (Sarle, 2000; Baxt; y White, 1995; Gallant, 1987). Ésta es actualmente la principal limitación de las ANN's.
- **No existen reglas para su implementación:** "Determinar el número de capas ocultas o el número de neuronas en cada capa forma todavía parte del arte del uso de las redes neuronales" Brown (2000). A pesar de que los numerosos heurísticos existentes pueden ser puntos de partida para la construcción de modelos basados en ANN's, lo cierto es que actualmente no existe una metodología clara y rigurosa a la hora de aplicar esta técnica. Es la experiencia del investigador en su uso, a través de un proceso ensayo-error, la que en última instancia se aplica en cada caso (Santín, 2003).

7 PLANTEAMIENTO DEL MODELO

En el presente capítulo se presentan los elementos de apoyo considerados para el desarrollo del modelo.

7.1 CONCEPTUALIZACIÓN DEL MODELO

Para el desarrollo del modelo, es necesario obtener gran cantidad de información relacionada en diferentes gráficos de control, que miden cierta variable de interés. Esta información debe representar los patrones que son involucrados en este estudio, y debe ser lo suficientemente amplia para que la red tenga mayor eficiencia. Sin embargo, debido a la poca disposición de datos en la industria con las características suficientes para el desarrollo del modelo, se simula una serie de datos sintéticos que representan los patrones de interés en los gráficos de control, y sirven como entrada al modelo. Los patrones que se tienen en cuenta son aquellos que se presentan con mayor frecuencia en los procesos fuera de control, y además, son los mayormente tratados por la comunidad científica con este tipo de modelos. Los patrones son producidos mediante simulación Montecarlo, para conformar la cantidad necesaria y entrenar el modelo adecuadamente. Los datos se generan en Microsoft Excel® versión 2007.

El entrenamiento del modelo es una de las fases más extensas, pues desde allí parte la arquitectura y rendimiento del sistema. Debido a la imposibilidad de conocer el diseño del modelo en primera instancia, se requiere hacer pruebas y modificar los parámetros y estructura de la red conforme al error alcanzado, para elaborar un modelo con desempeño aceptable. Este es uno de los inconvenientes más significativos de las ANN's.

La estructura es uno de los factores más influyentes en la eficiencia del modelo, por lo tanto se ejecutan corridas con diferentes números de neuronas ocultas, hasta obtener el rendimiento deseado. Del mismo modo, se alteran diferentes parámetros para mejorar la precisión del sistema.

Debido a que el número de neuronas de entrada al modelo debe ser igual al número de series de tiempo en los gráficos de control, el sistema solo podrá identificar patrones con series iguales a las relacionadas en el entrenamiento de la red. Por esto, el caso de estudio que se llevará a cabo, tendrá igual número de series de tiempo que el modelo tendrá de entradas.

Las salidas son independientes de las entradas y de las neuronas ocultas, y corresponden al número de patrones que identificará el modelo, al asignar a cada unidad de salida un patrón específico. Cada neurona de salida se activa cuando el sistema reconoce el patrón asignado a esa unidad de salida.

7.2 VARIABLES DEL MODELO

El control estadístico de procesos es una herramienta utilizada para el control y la mejora de la calidad de los productos y/o servicios. Los gráficos de control son un instrumento que entrega información del comportamiento de los procesos a través del tiempo. Esta información siempre debe ser de una variable o característica medible, que finalmente es lo que le interesa al usuario. El gráfico se desarrolla en términos de la variable de interés, conformando valores para la media (μ), desviación (σ) y límites de control superior e inferior.

Entre algunas de las características de calidad propensas a ser medidas y utilizadas en los gráficos de control, se encuentra el peso, longitud, diámetro, volumen, densidad, entre otros, dependiendo del proceso y variable de interés. Estas características son medidas y trazadas en el gráfico para analizar su comportamiento e inferir si el proceso está en control o no.

El desarrollo del modelo requiere gran cantidad de gráficos de control para extraer su información ilustrada, pero debido a la poca disponibilidad de datos en procesos reales, se hace necesario desarrollar valores sintéticos que simulen las variables de interés en un proceso cualquiera. Por lo tanto, se genera una cantidad de datos suficientes mediante simulación Montecarlo para desarrollar patrones que son utilizados como ejemplo de aprendizaje en el sistema (Gauri & Chakraborty, 2007).

Muchos de los modelos basados en ANN's están destinados a clasificar patrones en distintas áreas del campo científico. Por lo tanto, esta herramienta es utilizada en el presente estudio para reconocer diferentes patrones de comportamiento en los gráficos de control, que presentan algunos tipos de inestabilidades en los procesos. El modelo aquí relacionado incluye seis patrones que usualmente son evidenciados a los gráficos de control. Un patrón presenta normalidad y los otros cinco, describen diferentes tipos de inestabilidades en los procesos. Los patrones tomados en cuenta para el estudio son: (a) normal, (b) tendencia hacia abajo, (c) tendencia hacia arriba, (d) cambio hacia abajo, (e) cambio hacia arriba, (f) cíclico, representados en la figura 4 (Western-Electric, 1956). Los patrones desde (b) hasta (g) demuestran no aleatoriedades en los procesos, mientras que el patrón (a) no refleja inestabilidad. Cada uno de estos patrones de inestabilidad tiene sus causas de comportamiento, las cuales deben ser corregidas para contribuir en la calidad de los procesos.

En el modelo, el número de unidades de salida es igual a la cantidad de patrones en estudio, por lo que el modelo tiene seis salidas. Cada salida representa un tipo de patrón, por lo cual, si una salida se activa expresa que el patrón asignado a esa salida fue ingresado en la capa de entrada. La clasificación de estos patrones es ejecutada mediante límites binarios, es decir, dada una entrada se activa una salida que oscila entre 0 y 1. Estas salidas se expresan como en la Tabla 2.

Tabla 2 Salidas por cada patrón

Patrón	Salida
Normal	1 0 0 0 0 0
Tendencia hacia abajo	0 1 0 0 0 0
Tendencia hacia arriba	0 0 1 0 0 0
Cambio hacia abajo	0 0 0 1 0 0
Cambio hacia arriba	0 0 0 0 1 0
Cíclico	0 0 0 0 0 1

Fuente: Elaboración propia

En el anexo 2 se proporciona una breve explicación de las causas que pueden ocasionar estos tipos de patrones no aleatorios.

7.3 FORMULACIÓN DEL MODELO

A continuación se presentan los diversos elementos considerados en la formulación del modelo.

7.3.1 Patrones de muestra

Para desarrollar el modelo se debe recolectar muestras de patrones en gráficos de control reales. Pero debido al gran número de muestras necesarias para entrenar y validar el clasificador, no es viable en términos de tiempo y disposición de información, entrenar la red con cifras de procesos existentes. Por lo tanto, es indispensable producir los patrones de muestra utilizando un enfoque de simulación Montecarlo. Las siguientes ecuaciones son utilizadas por (Gauri & Chakraborty, 2007) para generar los patrones abordados en este estudio:

Patrón Normal:

$$Y(t) = \mu + r(t)\sigma \quad (1)$$

Donde $Y(t)$, es el valor de la observación en el tiempo t , μ es la media del proceso, σ es la desviación estándar y $r(t)$ es un valor aleatorio que sigue una distribución normal con media 0 y desviación estándar 1, $N(0,1)$.

1. Tendencia hacia abajo y tendencia hacia arriba:

$$Y(t) = \mu + r(t)\sigma \pm gt \quad (2)$$

Donde g es la magnitud del gradiente dado entre 0.05σ , y 0.1σ .

2. Cambio hacia arriba y cambio hacia abajo:

$$Y(t) = \mu + r(t)\sigma \pm ks \quad (5)$$

Donde s es la magnitud del cambio elegido aleatoriamente entre 1.5σ , y 2.5σ , y k es 0 o 1 dependiendo de la posición del cambio P así, $k = 1$ si $t \geq P$, de otro modo $k = 0$, donde P es la posición del cambio. En este caso y para el entrenamiento se simulan dos cambios en las posiciones 8 y 16 del gráfico de control. Las alteraciones son simuladas en estas posiciones, debido a que en estos posicionamientos la ANN permite mayor generalización del patrón (Gauri & Chakraborty, 2007).

3. Cíclico:

$$Y(t) = \mu + r(t)\sigma + \alpha \sin\left(\frac{2\pi t}{T}\right) \quad (4)$$

Donde α es la amplitud del ciclo de variación dado por un valor entre 1.5σ y 2.5σ , y T es el período de un ciclo compuesto por 8 intervalos de muestreo.

Es necesario tener en cuenta que estas fórmulas procuran mantener los datos dentro de los límites de control, pero difícilmente se mantienen debido a la distorsión que genera las aleatoriedades.

Según (Prat, Tort-Martorel, Grima, & Pozueta, 1998) un gráfico de control debe estar compuesto por al menos 20 series de tiempo. Para el caso de estudio, la información del proceso real, se encuentra en formatos de control con 24 observaciones consecutivas. Pero debido a la rigidez del modelo en este caso, se debe hacer el entrenamiento con gráficos de igual número de series de tiempo, a las utilizadas para evaluar finalmente el modelo. Por lo tanto, cada patrón se compone de 24 series de tiempo, y se utilizan como vectores de entrada al modelo.

Debido a que seis tipos de patrones son considerados en este estudio, se producen 3.600 (600X6) series para entrenar, validar y testear el sistema dividiendo la información en 70%, 15% y 15% respectivamente.

Es importante resaltar que el grupo de entrenamiento debe contener el mismo número de muestras para cada patrón. Esto es hecho para asegurar que la red no


estará sesgada hacia un tipo de patrón que haya sido entrenado más veces que otro.

7.3.2 Estructura del modelo

En general, una red neuronal es un sistema compuesto por una serie de procesadores simples interconectados por enlaces.

Existe gran variedad de estructuras y algoritmos de entrenamiento útiles en aplicaciones de ANN's. Redes tipo *Multilayer Perceptron* (MLP) con regla de aprendizaje *Backpropagation* han sido ampliamente utilizadas por investigadores - (Hassan, Shariff, Shaaroun, & Jamaluddin, 2003), (Gauri & Chakraborty, 2007), (Bhattacharyya & Chakraborty, 2009), (Addeh, Ebrahimzadeh, & Ranaee, 2011)- para resolver problemas de reconocimiento, por ser simples e idealmente adecuadas. En la figura 5, se representa un MLP de tres capas, donde los nodos representan las neuronas, los arcos son las interconexiones y las flechas indican la dirección del flujo de información. Las unidades en las capas de entrada, oculta y de salida son denotadas con los subíndices i , j y k respectivamente. Los enlaces entre neuronas son ponderados por W y sus superíndices indican la capa posterior.

Figura 5. Multilayer perceptron



Fuente: (Gauri & Chakraborty, 2007)

Su estructura básica comprende una capa de entrada –su tamaño depende del vector de entrada-, una o más capas ocultas -sus procesadores son ajustados a la estructura general de la red- y una capa de salida -obedece del número de clases del sistema. La capa de entrada recibe datos del exterior, mientras que las salidas entregan la información a otros sistemas, y los procesadores de las capas ocultas reciben y dan la información dentro del mismo modelo. Todos los procesadores de una capa están conectados con todas las unidades de la capa siguiente, y

asimismo ocurre el flujo de información, es decir, no existe retroalimentación entre unidades (Bhattacharyya & Chakraborty, 2009).

El sistema debe ser entrenado y probado antes de desarrollar las aplicaciones. En el aprendizaje supervisado, los grupos de entrenamiento comprenden vectores de entrada y las salidas esperadas por el usuario. El proceso de aprendizaje se lleva a cabo calculando el error, al propagar la información de entrada hacia la capa de salida, y comparar el resultado obtenido en las unidades de salida con las salidas deseadas. Este error es transmitido hacia las unidades de entrada reajustando los pesos de conexión de cada neurona basados en el error obtenido, con el fin de minimizarlo dependiendo del rendimiento especificado y la funciones de aprendizaje (Villanueva, 2002).

7.3.3 Configuración del modelo


En el caso de ANN's es preferible que el tamaño del modelo sea lo más reducido posible para ejecutar una eficiente computación. En el presente modelo se elabora un Multilayer perceptron de tres capas. El número de neuronas en la capa de entrada equivale a las veinticuatro series de tiempo utilizadas en el gráfico de control. El tamaño de la capa de salida corresponde al número de clases de patrones, es decir, cada procesador concuerda con uno de los seis tipos de patrones involucrados en este estudio.

Por otro lado, una de las desventajas que presenta esta herramienta es la imposibilidad de conocer a priori la arquitectura del modelo, por lo cual el número de neuronas en la capa oculta es seleccionado con base en resultados obtenidos, en la fase de entrenamiento, llevando a cabo un gran número experimentos variando el número de procesadores en la capa oculta y los datos de entrenamiento. Los experimentos son codificados en MATLAB® versión académica. Las funciones de transferencia y algoritmos de entrenamiento son utilizados durante los experimentos.

7.3.4 Funciones de transferencia

Según (Hudson, Hagan, & Demuth, 2012), una de las funciones de transferencia más utilizadas en los modelos Multilayer perceptron (MLP), es la función tangente hiperbólica (*tansig*). En la figura 6, se representa la función tangente hiperbólica que transforma la información ingresada que puede variar entre $-\infty$ y $+\infty$, al rango de -1 a 1.

Figura 6. Función de transferencia tangente hiperbólica



Fuente: (Hudson, Hagan, & Demuth, 2012)

Y su función es dada por:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (5)$$

Esta función de transferencia se emplea en las diferentes capas de la red para buscar el mejor desempeño del sistema. En el modelo empleado, se utiliza la función tangente hiperbólica en la capa oculta y de salida respectivamente

7.3.5 Algoritmo de entrenamiento

Investigaciones previas se han desarrollado para elegir un algoritmo de entrenamiento adecuado. Los algoritmos gradient descent with momentum and adaptive learning rate (*traingdx*), BFGS quasi-Newton (*trainbfg*), y Levenberg-Marquardt (*trainlm*), son evaluados para analizar su rendimiento como lo proponen (Gauri & Chakraborty, 2006). Los experimentos son codificados en MATLAB® versión académica usando su ANN toolbox (Hudson, Hagan, & Demuth, 2012). Después de ejecutar las pruebas correspondientes, el algoritmo *traingdx* es empleado para el entrenamiento del modelo, debido a que provee buen rendimiento y resultados consistentes. Este algoritmo es más eficiente que *trainlm* en términos de utilización de memoria. El *trainlm* converge más rápidamente que el *traingdx*, pero los resultados son poco consistentes. Finalmente el rendimiento del modelo se mide de acuerdo a la precisión de clasificación y al error cuadrático medio del modelo.

7.3.6 Entrenamiento y validación

La figura 7 muestra el procedimiento de entrenamiento del modelo y la tabla 3 denota los parámetros utilizados para esto.

El procedimiento comienza con la generación y presentación de datos teniendo en cuenta las series de tiempo a utilizar. La estandarización de la información

involucra la representación de los datos amparados en una distribución normal $N(0,1)$. Antes de empezar el entrenamiento del modelo, el sistema divide los datos para el entrenamiento (70%), validación (15%) y pruebas (15%), en forma aleatoria. Estos conjuntos de datos tienen el mismo número de muestras para cada tipo de patrón, con el objetivo de no sesgar los resultados del modelo.

El proceso se llevó a cabo desarrollando el aprendizaje de la red de forma iterativa. Durante el entrenamiento, se utilizan las muestras para actualizar los pesos de las conexiones y umbrales. Seguidamente, se utilizan los datos de validación para evitar el exceso de ajustes de los pesos del modelo. El proceso de entrenamiento de la red se detiene cuando el error de validación aumenta a un número determinado de iteraciones consecutivas. En este estudio el número máximo de errores de validación se establece en seis, ya que (Hudson, Hagan, & Demuth, 2012) recomiendan este valor para aplicaciones de ANN's, además de ser un valor considerable para evitar desviaciones en la generalización. A continuación, el modelo es sometido a pruebas preliminares. Con base en este grupo de pruebas, no se actualizan los pesos de la red, simplemente se utiliza para analizar el rendimiento de la red. Sin embargo, apoyado en el porcentaje de clasificación correcta de este proceso de prueba, se decide si la red requiere reentrenamiento o si se acepta el modelo entrenado.

La capacidad de generalización y precisión del modelo son motivos clave para su utilización en aplicaciones reales. Para ejecutar un buen entrenamiento, se ingresa al modelo los patrones generados previamente, así como las salidas deseadas con los siguientes parámetros de entrenamiento:


Tabla 3. Parámetros del modelo

Parámetros	Valores
Máximo número de épocas	300
Tasa de aprendizaje	0.1
Relación del aumento de la tasa de aprendizaje	1.05
Relación de disminución de la tasa de aprendizaje	0.7
Momentum constante	0.5
Error objetivo	0.001

Fuente: Elaboración propia

El entrenamiento se detiene cuando se logra obtener el error esperado, o en el momento que el número máximo de épocas se ha cumplido.

Figura 7. Proceso de entrenamiento del modelo



7.3.7 Fase de clasificación

Para mitigar el bajo rendimiento que puede presentar el sistema por causa de datos poco favorables y el número inadecuado de neuronas ocultas, se ejecutan diferentes ciclos de entrenamiento con distinto número de patrones y neuronas ocultas, dando como resultado cincuenta sistemas de clasificación entrenados con diferentes números de muestras. Estos modelos son nombrados S_{ij} donde $i=5...n=14$ representa el número de neuronas utilizadas en la capa oculta y $j=1...m=5$ simboliza el grupo de entrenamiento de la red; que para $j=1$ será una matriz 24X600 (100 series por cada patrón) aumentando en 100 la cantidad de muestras utilizadas por cada set de entrenamiento.

Este proceso se basa en la selección del mejor sistema de clasificación que se utilizará posteriormente en el caso de estudio.

7.4 RESULTADOS DEL ENTRENAMIENTO

Esta sección presenta los resultados y analiza el rendimiento del modelo de clasificación desarrollado. En el anexo 16 se muestra el *script* o código en lenguaje MATLAB del modelo clasificador utilizado finalmente.

7.4.1 Elección del clasificador

Al realizar el entrenamiento respectivo de los diferentes modelos, se determina cuál de estos presenta mejor precisión para finalmente ejecutar su aplicación en el caso de estudio.

Considerando las características del entrenamiento de las ANN's, su desarrolla el ejercicio basado en ensayo-error, hasta arrojar un resultado razonable para este estudio. El ejercicio arroja diez fases de entrenamiento y los resultados de entrenar cada modelo con cinco diferentes grupos de datos, se presentan en los anexos desde 3 hasta 12. Los resultados del desempeño del entrenamiento se resumen en la siguiente tabla.

Tabla 4. Porcentaje de precisión en el entrenamiento

		Grupos de entrenamiento				
		1	2	3	4	5
No. de Neuronas ocultas	5	%79,86	%74,1	%65,7	%78,1	%65,5
	6	%76,8	%62,2	%73,8	%75,8	%90,6
	7	%88,9	%90,8	%58,2	%93,5	%90,6

	8	%89,2	%70,5	%75	%91,2	%90,3
	9	%90,8	%86,1	%74	%93,3	%94,7
	10	%89,6	%88,8	%86,5	%92,2	%94,7
	11	%89,6	%87,7	%73,6	%90,5	%88,1
	12	%90,8	%89,2	%76	%89,2	%94,2
	13	%90,8	%87	%75,5	%92,7	%94,9
	14	%90,1	%83,1	%76,2	%93,7	%90,3

Fuente: Elaboración propia

Para elegir la arquitectura de la red y los datos de entrenamiento adecuados, se analizan los resultados mostrados en la tabla 4.

Al promediar los porcentajes de cada fila, se identifica la influencia de los datos de entrada en un modelo con determinado número de neuronas ocultas. En la tabla 5 se muestran los resultados destacando el dato de mayor valor, el cual indica que el modelo compuesto por 10 neuronas ocultas presenta el mejor desempeño al comparar los cinco tipos de entradas; de la misma manera evidencia que el menor error cuadrático medio se atribuye a la arquitectura de mejor rendimiento.

Tabla 5. Desempeño promedio de la arquitectura del entrenamiento

No. de neuronas ocultas	Porcentaje promedio de rendimiento	Promedio error cuadrático medio
5	%74,652	0,06602
6	%75,84	0,05786
7	%84,4	0,0403
8	%83,24	0,04406
9	%87,78	0,0363
10	%90,36	0,0299
11	%85,9	0,04032
12	%87,88	0,03208
13	%88,18	0,03178
14	%86,68	0,0364

Fuente: Elaboración propia

De la misma forma se obtiene el rendimiento que presenta el sistema, pero esta vez tomando en cuenta el promedio de las columnas de la tabla 4, lo cual indica el grupo de entrenamiento que obtuvo mejores resultados.

En la tabla 6, se presenta el rendimiento promedio de los cinco grupos considerados, para el entrenamiento de los diferentes modelos. Tomando en cuenta el mejor desempeño que presentaron los modelos, el grupo de datos número 5 supera los otros sets de entrenamiento, con un error cuadrático promedio considerablemente bajo.

Tabla 6. Desempeño promedio de los grupos de entrenamiento

Grupo de entrenamiento	Porcentaje promedio de rendimiento	Promedio error cuadrático medio
1	%87,64	0.03639
2	%81,95	0.047
3	%73,45	0.05767
4	%89,02	0.03108
5	%90,39	0.03537

Fuente: Elaboración propia

Finalmente tomando en cuenta el rendimiento de la arquitectura del modelo y el grupo de datos utilizado, el modelo clasificador elegido es entrenado con el grupo de datos número 5 compuesto por un set de 3.600 muestras (600 por cada clase de patrón), considerando una red estructurada por 24 neuronas de entrada, que representan 24 series de tiempo de los gráficos de control, 10 neuronas en la capa oculta, que hacen el trabajo de clasificación y 6 neuronas en la capa de salida, que interpreta seis patrones contemplados en este estudio (24X10X6).


7.4.2 Generalidades del entrenamiento

El entrenamiento de la red final que se utilizará para evaluar el caso de estudio, presenta características propias en cuanto a su desempeño y precisión. En la figura 8, se presentan aspectos generales respecto su entrenamiento.

En la parte superior del gráfico se observa un bosquejo de la representación gráfica de la red, seguido de algunas variables tomadas en cuenta para el manejo de la información, y por último se ve el progreso del entrenamiento donde se mencionan los criterios de detención del entrenamiento.

En el gráfico se observa que el algoritmo gradient descent with momentum and adaptive learning rate (*traingdx*,) fue utilizado para el entrenamiento de la red, así como las entradas que alimentan el modelo se dividen aleatoriamente, y su desempeño es medido en términos del error cuadrático medio, (*mse* por sus siglas en inglés) arrojando un valor final de 0.0174. También se evidencia que el entrenamiento se lleva a cabo en 130 corridas o épocas, y en alrededor de 7 segundos; esto reitera la velocidad para procesar información del algoritmo de entrenamiento. El proceso de entrenamiento termina cuando uno de los criterios de parada se cumple, en este caso proceso termina cuando ocurre un máximo de 6 fallas consecutivas permitidas en la validación del modelo.

Figura 8. Estado del entrenamiento



Fuente: Matlab® versión académica

7.4.3 Estado del modelo

Como se mencionó anteriormente, las ANN's son sistemas que no tienen memoria o una base de datos dispuesta para recordar una clase de patrón, sino que su capacidad de clasificación se basa en la asignación de pesos o ponderaciones a sus enlaces entre neuronas, es decir, que el entrenamiento de una red conlleva a que ésta tome un estado de equilibrio, de tal modo que sea capaz de reconocer

patrones de distintas clases. En el anexo 14 se observa la matriz de pesos (10X24) entre las neuronas de la primera capa, que representa los enlaces de las neuronas de la capa oculta y de la capa de entrada, (filas y columnas respectivamente).

La matriz de pesos de la segunda capa se muestra en la siguiente tabla, donde las columnas representan las neuronas de la capa oculta y las filas simbolizan las salidas.

Tabla 7. Matriz de pesos segunda capa

		Neuronas capa oculta									
Neuronas capa salida		1	2	3	4	5	6	7	8	9	10
	1	0,246	0,643	0,738	-1,489	-1,740	0,473	-0,234	-0,279	0,465	0,347
	2	0,810	0,735	0,026	-0,804	0,411	-0,139	-0,588	1,745	-0,077	-1,429
	3	0,894	0,201	1,113	1,584	-0,616	-0,406	1,030	-0,549	0,276	0,029
	4	0,489	-0,404	0,653	0,302	0,807	-0,306	0,654	0,642	-0,808	1,469
	5	-0,492	0,152	-1,654	0,634	-0,216	0,490	-0,097	-0,064	-0,643	0,710
	6	-0,443	0,561	0,046	-0,781	0,591	-0,521	-1,289	-1,610	0,258	0,637

Fuente: Elaboración propia

Estos pesos representan un estado de la red capaz de clasificar los patrones para los que fue inicialmente entrenada.

Los umbrales de las neuronas también inciden en el rendimiento del modelo, por lo tanto en la siguiente tabla se presentan los umbrales de cada neurona en la capa oculta y de salida.

Tabla 8. Umbrales de activación

	Capa oculta	Capa de salida
Neurona 1	-1,706	-1,802
Neurona 2	-1,243	-1,328
Neurona 3	1,329	-0,604
Neurona 4	-0,874	-1,026
Neurona 5	-0,764	-1,252
Neurona 6	0,672	-1,920
Neurona 7	-0,347	
Neurona 8	-0,748	
Neurona 9	1,333	
Neurona 10	-2,097	

Fuente: Elaboración propia

Estos umbrales representan el límite de activación de cada neurona de la capa oculta (10 neuronas) y de la capa de salida (6 neuronas). al igual que los pesos de los enlaces, los valores de estos umbrales se modifican por cada época.

7.4.4 Matriz de confusión

La matriz de confusión es una tabla que resume la tendencia del clasificador para reconocer un patrón correctamente de una clase específica, o cualquier otro de los cinco tipos de patrones tomados en cuenta. La matriz de confusión que se muestra en la tabla 9, presenta un resumen del nivel de error que obtiene el modelo en la fase de entrenamiento, validación y prueba. En el anexo 13 se observa detalladamente las equivocaciones del modelo en cada una de las tres etapas.

Para entender mejor la tabla, en la parte inferior e izquierda, los números del 1 al 6, representan los patrones involucrados en este estudio: el número 1 representa el patrón normal, el 2 tendencia hacia abajo, 3 tendencia hacia arriba, 4 cambio hacia abajo, 5 cambio hacia arriba y el número 6 representa el patrón cíclico

El patrón normal es confundido con los patrones tendencia hacia abajo en 5 ocasiones, tendencia hacia arriba en 12 y patrón cíclico en 2, conservando una asertividad del 96.8%. Por otro lado, el patrón tendencia hacia abajo, clasifica erradamente 13 muestras al equivocarse con el patrón normal y 21 con el patrón cambio hacia abajo y obtiene un nivel de precisión del 94.3%. El patrón tendencia hacia arriba, es confundido con el patrón normal en 7 oportunidades y con el patrón cambio hacia arriba en 13, y adquiere una exactitud del 96.7%. El patrón cambio hacia abajo es confundido con el patrón tendencia hacia arriba en 21 ocasiones, con una precisión del 96.5%. El patrón cambio hacia arriba, fue el más difícil de ser clasificado, tan solo con el 85.5% de las muestras, la confusión es producida con el patrón tendencia hacia arriba, al clasificar erradamente 87 muestras. El patrón cíclico es clasificado correctamente para el 100% de las muestras utilizadas.

Finalmente se puede considerar en general que la precisión presentada por el modelo es del 95.5%, para las 6 clases de patrones.

Tabla 9. Matriz de confusión

Salidas obtenidas	1	581 16,1%	13 0,4%	7 0,2%	0 0%	0 0%	0 0%	96,7% 3,3%
	2	5 0,1%	566 15,7%	0 0%	21 1%	0 0%	0 0%	95,6% 4,4%
	3	12 0,3%	0 0%	580 16,1%	0 0%	87 2,4%	0 0%	85,4% 14,6%
	4	0 0%	21 0,6%	0 0%	579 16,1%	0 0%	0 0%	96,5% 3,5%
	5	0 0%	0 0%	13 0,4%	0 0%	513 14,2%	0 0%	97,5% 2,5%
	6	2 0,1%	0 0%	0 0%	0 0%	0 0%	600 16,7%	99,7% 0,3%
		96,8% 3,2%	94,3% 5,7%	96,7% 3,3%	96,5% 3,5%	85,5% 14,5%	100,0% 0%	95,0% 5,0%
		1	2	3	4	5	6	
Salidas esperadas								

Fuente: Elaboración propia

En la tabla anterior se muestra que hay confusión en el proceso de clasificación en el reconocedor. En la matriz se evidencia una tendencia a confundir el patrón tendencia hacia arriba con el patrón cambio hacia arriba, y el patrón tendencia hacia abajo con el patrón cambio hacia abajo. Esta situación puede darse, debido a las características similares que presentan los patrones. Las confusiones entre los patrones tendencia abajo y arriba, puede ser causado por el ruido que presentan las aleatoriedades.

8 CASO DE ESTUDIO

Para evaluar del modelo de clasificación, se tiene en cuenta su aplicación en un proceso real en la industria.

Una empresa del sector azucarero del Valle del Cauca, hace su aporte a esta investigación al proveer información acerca del control estadístico del proceso de empaque en polietileno de azúcar refinada. La máquina *Discovery #5*, es diseñada para empaçar azúcar en presentación de 2.5 kilogramos.

El gráfico de control destinado a evaluar el proceso, es diseñado por la empresa y corresponde a un gráfico X. Cabe anotar que la representación de estos gráficos se desarrolla de manera manual, así como su interpretación.

Debido a la disponibilidad de información solo se logra obtener los límites de los gráficos de control y la muestra de un día completo que equivale a 24 series de tiempo para un intervalo de muestreo por hora.

Debido a restricciones de información por parte de la empresa, solo se logra obtener los parámetros tomados en cuenta para la implementación de los gráficos de control en este proceso, y son presentados en la siguiente tabla:

Tabla 10. Parámetros del gráfico caso de estudio

Límite de control superior (gr)	Límite de control central μ (gr)	Límite de control inferior (gr)	Intervalo de muestreo (min)	Tamaño de la muestra	Desviación estándar σ
2541.8	2526.8	2511.8	60	5	11.18


Tomando en cuenta esta información se obtiene la desviación estándar a modo informativo, teniendo en cuenta la fórmula (6) para hallar los límites de control mencionada por (Montgomery, 1992).

$$\mu \pm 3 \frac{\sigma}{\sqrt{n}} \quad (6)$$

La información detallada que se considera para evaluar el modelo desarrollado, se presenta en el anexo 15, y el resultado de su gráfico es mostrado en la figura 9. En la abscisa, se presentan las 24 series de tiempo que se muestrea el proceso, y en la ordenada el valor de la variable de interés que se pretende medir. También se grafican los límites de control y los promedios de las muestras por cada serie de tiempo.

Si se analiza detenidamente el gráfico, se observa que el proceso presenta normalidad en las primeras 8 series, además de presentar un fuerte cambio hacia arriba de su media, respecto al estándar establecido; incluso saliendo de sus límites de control. Esto indica que el proceso presenta un patrón no aleatorio, por lo tanto está fuera de control.

Figura 9. Gráfico de control caso de estudio



Fuente: Elaboración propia

8.1 EVALUACIÓN DEL CASO DE ESTUDIO

Para evaluar el caso de estudio, se debe presentar los datos del gráfico de control en un formato tal, que el modelo sea capaz de reconocer. Por esto, se ajustan los datos del gráfico en una matriz 24X1, y se ingresa al programa para realizar la valoración del proceso. Se ingresan las muestras que representan cada punto del gráfico de control y se simula la red con estos datos, para posteriormente obtener el resultado. En este sentido los resultados no son tan exactos como para entregar solo unos y ceros, por lo tanto se observan algunas aproximaciones. Esto también se puede dar debido al nivel de confusión que presenta el modelo. Es importante resaltar que el programa reconoce inmediatamente el patrón ingresado, es decir que el tiempo de procesamiento para clasificar los 6 tipos de patrones es mínimo.

Finalmente los resultados que arroja el modelo es una matriz 6X1 que representa cada uno de los patrones. En la siguiente tabla se presentan los resultados obtenidos.

Tabla 11. Resultados del caso de estudio

Patrón	Salida
Normal	0.0793
Tendencia hacia abajo	0.1644
Tendencia hacia arriba	0.6834
Cambio hacia abajo	0.0001
Cambio hacia arriba	0.9523
Cíclico	0.0301

Fuente: Elaboración propia

En la Tabla 11, se evidencia que el patrón cambio hacia arriba, presenta el mayor valor (0.9523), esto quiere decir que la neurona que representa este patrón es la de mayor activación. Por otro lado, la neurona que interpreta la salida del patrón tendencia hacia arriba, también se estimula aunque con menos fuerza (0.6834). Además de que esto puede ocurrir debido a las similitudes que presentan los dos tipos de patrones, también concuerda con los resultados mostrados en la tabla 9, los cuales resaltan las confusiones que puede presentar la red.

Tomando en cuenta que el modelo de clasificación, ha identificado que el caso de estudio se encuentra fuera de control estadístico, al presentar un patrón con un cambio repentino de la media hacia arriba, lo siguiente es analizar cuáles son las causas que pueden ocasionar este patrón.

Cuando se presenta este tipo de patrón, usualmente puede ser atribuido a solo una causa de variación según (Western-Electric, 1956). Si se analiza detenidamente el gráfico, se puede observar que el cambio hacia arriba, ocurre después de las primeras 8 horas de trabajo, por lo tanto es posible que el cambio de operario responsable del proceso, sea la causa que ocasionó el desplazamiento de la media del proceso. También este comportamiento, pudo haberse dado por un cambio en el tipo de material que está procesando la máquina; por ejemplo un tipo de azúcar diferente ingresada después de la octava serie de tiempo, puede ser la causa de variación no natural, afectando la calibración de la máquina y asimismo todo el proceso.

Finalmente, el modelo presenta un buen nivel de consistencia en cuanto al caso de estudio, y clasifica oportunamente el patrón presentado.

9 CONCLUSIONES

- Actualmente interpretar los gráficos de control, se ha convertido en una labor con alto grado de subjetividad por la heurística utilizada, con el fin de entender las características de los patrones en estos gráficos. El objetivo de este estudio es implementar un modelo capaz de clasificar patrones que reflejan inestabilidad en los procesos, mediante una técnica de reconocimiento autónomo.
- La diversidad de técnicas utilizadas para el reconocimiento de patrones en gráficos de control, refleja la importancia que se ha prestado por parte de los investigadores al control estadístico de procesos, y comprueba la viabilidad del uso de técnicas de clasificación para evaluar gráficos de control. En este estudio específicamente, se opta por utilizar redes neuronales artificiales como la herramienta de clasificación más conveniente.
- Con base en la generación de números aleatorios, los seis patrones comúnmente presentados en los gráficos de control, son clasificados utilizando una red tipo *Multilayer Perceptrón* (MLP) entrenada con algoritmo de entrenamiento *Backpropagation*. El rendimiento del modelo se estudió ampliamente usando datos sintéticos. Los resultados numéricos del modelo desarrollado, revelan que puede desempeñarse bien en aplicaciones de procesos en tiempo real, debido a su exactitud y consistencia.
- La red neuronal utilizada, se entrenó siendo capaz de detectar y clasificar de manera correcta los seis patrones involucrados en este estudio, con desempeño del 95% en su precisión, lo cual según algunos investigadores es el rendimiento esperado para modelos sin preprocesamiento de información u optimización de parámetros.
- El análisis de la matriz de confusión indica que el reconocedor tiene una tendencia general para confundir los patrones tendencia hacia arriba y tendencia hacia abajo, con los patrones cambio hacia arriba y cambio hacia abajo respectivamente. Esto indica que el rendimiento del clasificador puede ser mejorado para discriminar mejor estos patrones utilizando herramientas de optimización o de análisis de datos.
- La implementación de la herramienta investigada en este estudio, es realizada en una empresa del sector azucarero del Valle del Cauca para el proceso de empaque en polietileno de azúcar refinada en presentación de 2.5Kg. La capacidad del proceso es establecido por la empresa, así como el gráfico de control, sus parámetros y variables. La aplicación del modelo resulta factible desde el punto de vista de los patrones de inestabilidad,

presentando un resultado efectivo y ágil al identificar el estado de control del proceso caso de estudio.

- Los resultados del caso de estudio evaluado, muestran la tendencia del modelo para confundir ciertos patrones con características similares, por esto se activan varias neuronas en la matriz de resultado. De igual manera, se observa la consistencia de la red al excitar fuertemente la neurona que representa la salida correcta, confirmando así su aplicación en procesos industriales reales.
- Estas herramientas de reconocimiento de patrones aplicadas al control estadístico de procesos con alto nivel de asertividad y eficiencia, elimina totalmente los sesgos que se puedan presentar por parte del personal entrenado para esta labor, así como ayuda a mitigar los errores humanos que producen costos por producción defectuosa.
- Para su aplicación en procesos reales, es necesario un cambio de enfoque en la forma de interpretar los gráficos de control, pues bajo el uso de redes neuronales, se debe poner especial atención en el entrenamiento del modelo para identificar patrones de interés, mientras que tradicionalmente la tendencia es entrenar al personal para que los reconozca.
- Como método de reconocimiento de patrones de uso industrial, esta investigación indica que su uso es factible y de buen pronóstico, basados en los resultados obtenidos del caso de estudio, y datos obtenidos por generación de números aleatorios. De cualquier manera, esta y como muchas otras investigaciones apuntan al uso de redes neuronales artificiales, como técnica de inspección de variables aleatorias en procesos de producción.
- Como ampliación del modelo, se puede pensar en estandarizar las causas de variación en cada proceso, para desplegar las causas asignables que pueden haber ocasionado la desviación, y asimismo las acciones a tomar, de acuerdo al patrón identificado por el clasificador.
- Finalmente, para futuros estudios es posible pensar en el desarrollo de modelos de clasificación con información preprocesada, y hacer un análisis exhaustivo de los sistemas.
- También es posible pensar en hacer uso de técnicas de optimización, con el fin de contribuir a mejorar la precisión de los modelos basados en redes neuronales artificiales.

10 BIBLIOGRAFÍA

- Addeh, J., Ebrahimzadeh, A., & Ranaee, V. (2011). Control chart pattern recognition using adaptive backpropagation artificial neural networks and efficient features. *ICCIA*, 742-746.
- Addeh, J., Ebrahimzadeh, A., Azarbad, M., & Ranaee, V. (2013). Statistical process control using optimized neural networks: A case study. *Elsevier Ltd.*, 1-11.
- Anagun, A. S. (1998). A neural network applied to pattern recognition in statistical process control. *Elsevier Ltd.*, 185-188.
- Bhattacharyya, K., & Chakraborty, S. (2009). Recognition of quality control chart patterns based on backpropagation neural network. *IEEE*, 1124-1128.
- Caivano, D. (2005). Continuous software process improvement through statistical process control. *IEEE*.
- Cortes, C., & Vladimir, V. (1995). Support vector networks. *Machine learning* 20, 273-297.
- Das, P., & Banerjee, I. (2010). An hybrid detection system of control chart patterns using cascaded SVM and neural network-based detector. *Springer*, 287-296.
- Del Brío, B., & Sanz, A. (2002). *Redes neuronales y sistemas difusos*. Madrid: Alfaomega.
- Du, S., Huang, D., & Lv, J. (2013). Recognition of concurrent control chart patterns using wavelet transform decomposition and multiclass support vector machines. *Elsevier*, 683-695.
- Ebrahimzadeh, A., & Ranaee, V. (2009). A Hybrid Intelligent Technique for Recognition of Control Chart Patterns. *IEEE*, 32-36.
- Ebrahimzadeh, A., & Ranaee, V. (2010). Control chart pattern recognition using an optimized neural network and efficient features. *Elsevier Ltd.*, 387-393.
- Ebrahimzadeh, A., Ranaee, V., & Ghaderi, R. (2010). Application of the PSO-SVM model for recognition of control chart patterns. *Elsevier Ltd.*, 577-586.
- Eljach, F., Penagos, G., & Peña-Baena, R. (2006). Evaluación del uso de las cartas de control X, EWMA y CUSUM en un sistema de control de calidad para procesos no correlacionados. *Ingeniería & Desarrollo*, 35-44.
- Fatemi, S., Lesany, S., & Koochakzadehc, A. (2011). Recognition of unnatural patterns in process control charts through combining two types of neural networks. *Elsevier B.V.*, 5444-5456.
- Freeman, J., & David, S. (1993). Redes neuronales algoritmos, aplicaciones y tecnicas de programación. En J. Freeman, & S. David, *Redes neuronales algoritmos, aplicaciones y tecnicas de programación* (págs. 1-20). Addison-Wesley/Diaz de Santos.
- Gauri, S., & Chakraborty, S. (2006). A study on the various features for effective control chart pattern recognition. *Springer*, 385-398.
- Gauri, S., & Chakraborty, S. (2007). Improved recognition of control chart patterns using artificial neural networks. *Springer-Verlag*, 1191-1201.

- Ghiasabadi, A., Noorossana, R., & Saghaei, A. (2013). Identifying change point of a non-random pattern on X control chart using artificial neural networks. *Springer*, 1623-1630.
- Guh, R.-S., & Hsieh, Y.-C. (1999). A Neural Network Based Model for Abnormal Pattern Recognition of Control Charts. *Elsevier Science Ltda*, 97-108.
- Gutiérrez, P., Vásquez, J., Hernández, M., Hernández, S., & López, I. (2012). Uso de la red neuronal Perceptrón para detección de cambios pequeños en la media en los gráficos de control. *LACCEI*, 1-10.
- Hachicha, W., & Ghorbel, A. (2012). A survey of control-chart pattern-recognition literature (1991–2010) based on a new conceptual classification scheme. *Elsevier Ltd.*, 204-222.
- Hassan, A., Shariff, M., Shaaroun, A., & Jamaluddin, H. (2003). Improved SPC chart pattern recognition using statistical features. *Taylor & Francis Ltd*, 1587-1603.
- Hudson, M., Hagan, M., & Demuth, H. (2012). *Neural network toolbox user's guide*. Natick: Mathworks.
- Koutras, M. V., Bersimis, S., & Maravelakis, P. E. (2007). Statistical process control using Shewhart control charts with supplementary run rules. *Springer*, 207-224.
- Kumar, S., & Chakraborty, S. (2006). A study on the various features for effective control chart pattern recognition. *Springer*, 385-398.
- Kumar, S., & Chakraborty, S. (2008). Improved recognition of control chart patterns using artificial neural networks. *Springer*, 1191–1201.
- Lavangnananda, K., & Kasikitsakulphol, S. (2010). Systematic Study to Assess Neural Networks' Capability. *IEEE*, 718-722.
- Lu, C., Shao, Y., Li, P., & Wang, Y. (2010). Recognizing mixture control chart patterns with independent component analysis and Support vector machine. *Springer*, 426-431.
- Luguer, G. F. (2008). *Artificial Intelligence*. Albuquerque: Pearson.
- Masood, I., & Hassan, A. (2008). Application of full factorial experiment in designing a ANN-based control chart pattern recognizer. *IGCES*.
- McCulloch, W., & Pitts, W. (1943). A logical calculus of ideas immanent in nervous activity. *Bulletin of mathematical biophysics*, 115-133.
- McCulloch, W., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of mathematical biophysics*, 115-133.
- Montgomery, D. C. (1992). *Introduction to statistical control quality*. John Wiley & Sons, Inc.
- Oakland, J. S. (2008). *Statistical Process Control*. Butterworth-Heinemann is an imprint of Elsevier.
- Prat, A., Tort-Martorel, X., Grima, P., & Pozueta, L. (1998). *Control y mejora de la calidad*. UPC.
- Pugh, G. (1989). Synthetic neural networks for process control. *Computers and Industrial Engineering*, 24-26.
- Ranaee, V., & Ebrahimzadeh, A. (2011). Control chart pattern recognition using a novel hybrid intelligent method. *Elsevier Ltd.*, 2676-2686.

- Rosenblatt, F. (1962). *Principles of neurodynamics*. New York: Spartan Books.
- Ruiz, A., & Rojas, F. (2006). Control Estadístico de Procesos. En A. R. Rojas, *Control Estadístico de Procesos* (pág. 10). Madrid.
- Rumelhart, D., & Hinton, G. (1986). Learning representations by backpropagating errors. *Nature*, 533.
- Rumelhart, D., & McClelland, J. (1986). *Parallel distributed processing*. Cambridge: MIT Press.
- Santín, D. (2003). Eficiencia técnica y redes neuronales: Un modelo para el cálculo del valor añadido en educación. Madrid, España.
- Sarraute, C. (6 de Diciembre de 2007). Aplicación de las redes neuronales al reconocimiento de sistemas operativos. Buenos Aires, Argentina.
- Shao, Y., Lin, Y., & Chan, Y. (2011). Integrated use of ICA and ANN to recognize the mixture control chart patterns in a process. *Springer*, 218-227.
- Soria, E., & Blanco, A. (2001). Redes Neuronales Artificiales. *ACTA*, 25-33.
- Varela, E., & Campbells, E. (2011). Redes neuronales artificiales: Una revisión del estado del arte, aplicaciones y tendencias futuras. *Investigación y Desarrollo en TIC*, 18-27.
- Villanueva, M. d. (2002). *Las redes neuronales artificiales y su importancia como herramienta en la toma de decisiones*. Lima: UNMSM.
- Wang, C., Dong, T., & Kuo, W. (2008). A hybrid approach for identification of concurrent control chart patterns. *Springer*, 409-419.
- Western-Electric. (1956). *Statistical quality control handbook*. New York.
- Wu, S. (2011). Intelligence statistical process control in cellular manufacturing based on SVM. *Springer*, 113-120.
- Yang, J. (2009). Intelligent Recognition Research of Control Charts Patterns. *IEEE*.
- Yang, M.-S., & Yang, J.-H. (2009). On Parameter Estimation of Control Chart Patterns Using RBF Neural Network. *IEEE*, 1498-1502.
- Yu, J., Xi, L., & Wu, B. (2007). A Neural Network Ensemble Approach for the Recognition of SPC Chart Patterns. *International Conference on Natural Computation*.
- Zorriassatine, F., & Tannock, T. (1998). A review of neural networks for statistical process control. *Journal of Intelligent Manufacturing*, 209-224.

ANEXOS

Anexo 1. Matriz de comparación modelo-autor

AUTOR/MODELO	Perceptrón multicapa (MLP)	Learning vector quantization (LVQ)	Radial basis function (RBF)	Probabilistic neural network (PNN)	Elman-backpropagation network (ELM)	Layer recurrent network (LRN)	Nonlinear autorregresive network with exogenous inputs (NARX)	Híbrido LVQ-MLP
Anagun, A., (1998)	X							
Gutiérrez, et al. (2012)	X							
Guh, R., (1999)	X							
Yu, J., (2007)	X							
Masood, I., (2008)	X							
Battacharyya, K., (2009)								
Ghiasabadi, A., (2013)	X							
Lavagnananda, K., (2010)	X	X		X	X	X	X	
Ebrahimzadeh, A., (2009)			X					
Fatemi, S., (2011)								X
Ebrahimzadeh, A., (2010)			X					
Addeh, J., (2011)	X							
Gauri, K., (2007)	X							
Hassan, A., (2003)	X							
Yang, M., (2009)	X							
Addeh, J., (2013)	X		X	X				

Fuente: Elaboración propia

Anexo 2. Causas de variación

Patrón	Descripción
Tendencia	La tendencia, ya sea hacia arriba o hacia abajo, es un movimiento gradual continuo en una dirección. Este tipo de patrón se concibe debido al deterioro gradual de los componentes críticos del proceso o equipo. También, la fatiga en los operadores es una causa de esta variación, además de la temperatura, la cual muchas veces es una causa que afecta la calidad de los productos ostensiblemente, y puede ser eliminada.
Cambio	Los cambios en la media, se pueden presentar debido a alteraciones en el método de trabajo, en materiales, operadores e incluso por cambios en los métodos de inspección. También se ve reflejado este patrón, por la motivación o atención del personal.
Cíclico	Este cambio puede ser generado por cambios sistemáticos en el medio ambiente como temperatura, la rotación regular de las máquinas u operadores, variables como presión o tensión afectan la máquina manifestando este comportamiento en los gráficos. También los programas de mantenimiento y desgaste de piezas afectan el proceso de esta manera.

Fuente: (Montgomery, 1992)

Anexo 3. Fase de entrenamiento 1

Clasificador Sij	% de clasificación	Error entrenamiento	No. Épocas
S5.1	79,86	0,0581	104
S5.2	74,1	0,073	119
S5.3	65,7	0,075	110
S5.4	78,1	0,048	122
S5.5	75,5	0,076	114

Fuente: Elaboración propia

Anexo 4. Fase de entrenamiento 2

Clasificador Sij	% de clasificación	Error entrenamiento	No. Épocas
S6.1	76,8	0,0653	113
S6.2	62,2	0,0794	124
S6.3	73,8	0,0555	113
S6.4	75,8	0,0503	116
S6.5	90,6	0,0388	122

Fuente: Elaboración propia

Anexo 5. Fase de entrenamiento 3

Clasificador Sij	% de clasificación	Error entrenamiento	No. épocas
S7.1	88,9	0,0316	155
S7.2	90,8	0,0257	141
S7.3	58,2	0,083	120
S7.4	93,5	0,0216	144
S7.5	90,6	0,0396	110

Fuente: Elaboración propia

Anexo 6. Fase de entrenamiento 4

Clasificador Sij	% de clasificación	Error entrenamiento	No. épocas
S8.1	89,2	0,0316	111
S8.2	70,5	0,0667	97
S8.3	75	0,0532	119
S8.4	91,2	0,0316	117
S8.5	90,3	0,0372	106

Fuente: Elaboración propia

Anexo 7. Fase de entrenamiento 5

Clasificador Sij	% de clasificación	Error entrenamiento	No. Épocas
S9.1	90,8	0,0369	124
S9.2	86,1	0,0409	120
S9.3	74	0,0575	120
S9.4	93,3	0,0193	146
S9.5	94,7	0,0269	110

Fuente: Elaboración propia

Anexo 8. Fase de entrenamiento 6

Clasificador Sij	% de clasificación	Error entrenamiento	No. Épocas
S10.1	89,6	0,0257	120
S10.2	88,8	0,0297	148
S10.3	86,5	0,046	123
S10.4	92,2	0,0274	120
S10.5	94,7	0,0207	117

Fuente: Elaboración propia

Anexo 9. Fase de entrenamiento 7

Clasificador Sij	% de clasificación	Error entrenamiento	No. épocas
S11.1	89,6	0,0298	123
S11.2	87,7	0,0389	117
S11.3	73,6	0,0631	111
S11.4	90,5	0,0352	140
S11.5	88,1	0,0346	121

Fuente: Elaboración propia

Anexo 10. Fase de entrenamiento 8

Clasificador Sij	% de clasificación	Error entrenamiento	No. épocas
S12.1	90,8	0,0276	144
S12.2	89,2	0,0307	123
S12.3	76	0,0471	119
S12.4	89,2	0,0295	113
S12.5	94,2	0,0255	121

Fuente: Elaboración propia

Anexo 11. Fase de entrenamiento 9

Clasificador Sij	% de clasificación	Error entrenamiento	No. épocas
S13.1	90,8	0,0249	137
S13.2	87	0,0422	107
S13.3	75,5	0,0491	124
S13.4	92,7	0,0249	119
S13.5	94,9	0,0178	127


Fuente: Elaboración propia

Anexo 12. Fase de entrenamiento 10

Clasificador Sij	% de clasificación	Error entrenamiento	No. épocas
S14.1	90,1	0,0324	113
S14.2	83,1	0,0428	108
S14.3	76,2	0,0472	115
S14.4	93,7	0,023	127
S14.5	90,3	0,0366	109

Fuente: Elaboración propia

Anexo 13. Matrices de confusión



Fuente: Matlab® versión académica

Anexo 14. Matriz de pesos primera capa

		Neuronas capa entrada											
Neuronas capa oculta		1	2	3	4	5	6	7	8	9	10	11	12
	1	0,314	-0,579	0,204	-0,153	0,537	0,430	0,186	-0,124	0,097	0,233	-0,290	0,261
	2	0,366	0,022	-0,418	0,204	-0,307	0,265	-0,235	-0,302	-0,332	0,512	0,447	0,262
	3	-0,118	0,155	0,152	0,373	0,301	0,433	0,453	-0,940	-0,551	-0,811	-0,602	-0,352
	4	0,147	0,270	-0,100	0,188	-0,015	0,219	0,535	0,361	0,598	0,482	0,460	0,337
	5	0,488	0,215	0,466	0,041	-0,229	-0,496	-0,262	-0,178	-0,404	-0,271	-0,095	-0,089
	6	0,261	-0,309	0,116	0,321	0,250	0,340	0,412	-0,137	0,057	-0,188	0,377	0,439
	7	-0,185	-0,091	-0,111	0,147	0,361	0,534	0,239	-0,396	-0,731	-0,740	-0,628	-0,356
	8	-0,425	-0,093	-0,124	-0,027	0,399	0,472	0,043	-0,133	-0,527	-0,676	-0,439	-0,512
	9	0,227	0,314	-0,065	0,043	0,154	-0,195	0,232	-0,457	-0,577	-0,485	0,173	-0,044
	10	0,143	0,514	0,314	0,424	0,245	0,228	0,390	-1,101	-0,930	-0,326	-0,852	-0,556
Neuronas capa oculta		13	14	15	16	17	18	19	20	21	22	23	24
	1	-0,358	-0,400	0,017	0,116	0,325	0,111	-0,333	-0,104	0,491	-0,133	0,404	-0,007
	2	-0,007	0,071	0,338	0,026	-0,473	-0,033	-0,117	0,358	0,173	-0,038	-0,305	-0,047
	3	-0,436	-0,280	-0,592	-0,252	-0,341	-0,077	-0,141	-0,129	-0,339	0,352	0,316	0,031
	4	0,675	0,474	0,682	0,562	0,582	0,246	0,462	0,762	0,519	0,815	0,868	0,998
	5	-0,652	-0,829	-0,596	-0,489	-0,168	-0,243	-0,246	-0,368	-0,861	-0,928	-0,664	-0,706
	6	0,582	0,594	-0,020	-0,169	-0,020	-0,347	0,424	-0,107	0,250	0,138	0,211	0,035
	7	-0,354	-0,122	0,054	-0,140	-0,148	0,039	0,211	0,323	0,566	0,063	0,204	0,390
	8	0,106	-0,065	0,055	-0,306	-0,609	-0,684	-0,649	-0,895	-0,467	-0,429	-0,640	-0,787
	9	-0,389	-0,651	-0,488	-0,026	0,218	-0,416	-0,528	-0,419	0,266	-0,619	-0,338	-0,089
	10	-0,527	-0,713	-0,294	-0,168	-0,615	-0,282	-0,198	-0,408	-0,257	0,239	0,012	-0,194

Fuente: Elaboración propia

Anexo 15. Datos caso de estudio

Hora muestreo	Número de muestra					Promedio muestra
	1	2	3	4	5	
06:30	2625,1	2634,7	2416,9	2520,1	2433,1	2525,98
07:30	2621	2160,3	2606,7	2634,4	2642,6	2533
08:30	2530,7	2516,7	2435,4	2547,7	2619,3	2529,96
09:30	2512,3	2433,4	2635,1	2641,3	2430,6	2530,54
10:30	2621,8	2626,5	2430,3	2441,7	2539	2531,86
11:30	2490,3	2636,4	2433,1	2630,6	2446,7	2527,42
12:30	2633,5	2644,7	2419,2	2442,3	2516,7	2531,28
13:30	2636,4	2428,1	2630,5	2445,3	2534,7	2535
14:30	2630,2	2582,4	2595,6	2442,9	2527,6	2555,74
15:30	2548,1	2565,7	2578,6	2522,4	2536,2	2550,2
16:30	2536,2	2542,6	2545,1	2552,7	2539,1	2543,14
17:30	2548,2	2556,2	2561,4	2564,9	2538,2	2553,78
18:30	2557,3	2544,1	2561,4	2525,4	2544,7	2546,58
19:30	2550,2	2548,1	2553,3	2555,9	2550,1	2551,52
20:30	2542,1	2560,7	2571,1	2536,5	2542,9	2550,66
21:30	2586,1	2576,9	2531,9	2518,1	2559,7	2554,54
22:30	2520,4	2582,1	2562,7	2522,4	2575,7	2552,66
23:30	2549,4	2567,6	2548,2	2567,7	2538,4	2554,26
00:30	2591,1	2536,3	2544,9	2535,2	2552,3	2551,96
01:30	2551,7	2527,5	2530,7	2575,1	2560,9	2549,18
02:30	2552,5	2586,7	2566,1	2530,4	2563,1	2559,76
03:30	2580,1	2542,3	2550,9	2572,3	2538,2	2556,76
04:30	2545,7	2512,1	2553,5	2547,1	2565,6	2544,8
05:30	2506,1	2577,9	2528,2	2551,7	2567,2	2546,22

Fuente: Elaboración propia

Anexo 16. Script del modelo

```
%Resolver el problema de reconocimiento de patrones en gráficos de
control mediante una red neuronal
%Se definen las siguientes variables:
%entrada100 = patrones de entrada.
%salida100 = salidas esperadas.
%Se define el número de neuronas ocultas de la red

hiddenLayerSize = 10;

%Se crea la red para el reconocimiento de patrones
%Se utiliza el algoritmo de entrenamiento traingdx:

net = patternnet(hiddenLayerSize,'traingdx');%gradient with momentum
%and adaptive learning rate backpropagation

%Los parámetros de la red son:

net.trainParam.epochs=300;%Máximo número de épocas a ejecutar
net.trainParam.lr=0.1;%Tasa de aprendizaje
net.trainParam.lr_inc=1.05;%Relación de aumento de la tasa de aprendizaje
net.trainParam.lr_dec=0.7;%Relación de disminución de la tasa de
aprendizaje
net.trainParam.goal=1e-3;%Error objetivo de la red
net.trainParam.mc=0.5;%Momentum constante

%Se inician los pesos de las conexiones aleatoriamente

net.inputWeights{1, 1}.initFcn = 'rands';
net.layerWeights{2, 1}.initFcn = 'rands';

%Los umbrales se inician aleatoriamente

net.biases{1}.initFcn = 'rands'
net.biases{2}.initFcn = 'rands'

%Para seleccionar los gráficos de rendimiento de la red

net.plotFcns =
{'plotperform','plottrainstate','ploterrhist','plotregression','plotconfu
sion'};

%Se tiene en cuenta la función de transferencia 'tansig' en las dos capas
%de la red

net.layers{1}.transferFcn = 'tansig'; %Hiperbolic tangent sigmoid
net.layers{2}.transferFcn = 'tansig';%Hiperbolic tangent sigmoid

%Entrenamiento de la red

[net,tr] = train(net,entradas600,salidas600);
```

```

%Pruebas de sensibilidad de la red

outputs = net(entradas600); %Salidas de la red por cada patrón
errors = gsubtract(salidas600, outputs); %Diferencia entre las salidas
deseadas y los resultados de la red
performance = perform(net, salidas600, outputs); %Rendimiento general de la
red en términos del error cuadrático medio

%Desempeño del entrenamiento, validación y tests

trainTargets = salidas600 .* tr.trainMask{1};
valTargets = salidas600 .* tr.valMask{1};
testTargets = salidas600 .* tr.testMask{1};
trainPerformance = perform(net, trainTargets, outputs)
valPerformance = perform(net, valTargets, outputs)
testPerformance = perform(net, testTargets, outputs)

%Visualizar los pesos de la red en las dos capas

pesos1racapa = net.IW{1};
pesos2dacapa = net.LW{2,1};

%Visualizar los umbrales en cada neurona de la red
umbrales1racapa = net.b{1};
umbrales2dacapa = net.b{2};

%Evaluación del caso de estudio

resultcasoestudio = sim(net, casoestudio);

%Ver estructura de la red

view(net)

%Interpretación de resultados

[cual, donde] = max(resultcasoestudio);

if donde==1
    disp('PATRONNORMAL')
elseif donde==2
    disp('TENDENCIAARRIBA')
elseif donde==3
    disp('TENDENCIAABAJO')
elseif donde==4
    disp('CAMBIOABAJO')
elseif donde==5
    disp('CAMBIOARRIBA')
elseif donde==6
    disp('PATRONCICLICO')
end

```

Fuente: Elaboración propia