

DOI: <https://doi.org/10.47300/actasidi-unicyt-2024-08>

# DESARROLLO DE UN CLASIFICADOR POR MEDIO DE REDES NEURONALES Y LOS K VECINOS: UN CASO DE ESTUDIO EN EL SECTOR TEXTIL

**Barrios Sánchez, Jorge Manuel**

Universidad de Guanajuato, Campus Irapuato-Salamanca, Sede Yuriria  
Yuriria, México

[jm.barriosanchez@ugto.mx](mailto:jm.barriosanchez@ugto.mx)

<https://orcid.org/0000-0003-3528-0922>

**Jiménez Velandia, Lowduim Dario**

Universidad de Boyacá, Grupo de investigación LOGyCA  
Tunja, Colombia

[ldjimenez@uniboyaca.co](mailto:ldjimenez@uniboyaca.co)

<https://orcid.org/0009-0008-0412-3493>

**López Villagómez, José Manuel**

Universidad de Guanajuato, Campus Irapuato-Salamanca, Sede Yuriria  
Yuriria, México

[jm.lopezvillagomez@ugto.mx](mailto:jm.lopezvillagomez@ugto.mx)

<https://orcid.org/0009-0006-8460-5331>

**López Moreno, Nicolas Alberto**

Universidad de Guanajuato, Campus Irapuato-Salamanca, Sede Yuriria  
Yuriria, México

[an.lopezmoreno@ugto.mx](mailto:an.lopezmoreno@ugto.mx)

<https://orcid.org/0009-0005-7805-0395>

## RESUMEN

Este trabajo de investigación se centra en la clasificación de la calidad del proceso de corte en la fabricación de camisetas para adultos de talla grande, implementado en una PYME del sector textil ubicada en la región sur del estado de Guanajuato. Se consideran seis características clave que determinan si el proceso de corte es eficiente o no. El objetivo principal es desarrollar y comparar dos tipos de clasificadores aplicables al proceso textil. Para ello, se recopilaron 100 muestras que incluyen mediciones del largo y ancho del cuerpo de la prenda, el largo y ancho de las mangas, así como los desperdicios generados durante el corte de ambas partes. Se entrenó un clasificador K-Medias con 70 datos de entrenamiento, 15 de validación y 15 de prueba, logrando una precisión del 82.75% en la clasificación.

**Palabras clave:** Clasificación de calidad; proceso de corte; industria textil; K-Means; Redes neuronales; eficiencia

## ABSTRACT

This research focuses on the classification of the quality of the cutting process in the manufacturing of large-size adult t-shirts, implemented in an SME in the textile sector located in the southern region of the state of Guanajuato. Six key characteristics are considered to determine whether the cutting process is efficient or not. The main objective is to develop and

compare two types of classifiers applicable to the textile process. For this, 100 samples were collected, including measurements of the length and width of the garment's body, the length and width of the sleeves, as well as the waste generated during the cutting of both parts. A K-Means classifier was trained with 70 training data, 15 validation data, and 15 test data, achieving an accuracy of 82.75% in classification.

**Keywords:** Quality classification; cutting process; textile industry; K-Means; neural networks; efficiency

## 1. INTRODUCCIÓN

El sector textil se considera una actividad de las denominadas “maduras”, y sin embargo está demostrando una alta capacidad de innovación y de avance tanto a los cambios de temporada, como a las modificaciones funcionales y estéticas requeridas por la evolución cultural, especialmente por la presión de consumidores exigentes, la inserción de nuevos competidores y nuevas oportunidades para las PYMES (Consultivo A.C, 2007); siendo la apuesta por la innovación continua lo que da al sector un carácter estable y una dimensión estratégica. La industria textil es un sector significativo para la economía mexicana, tanto en términos de generación de empleo como de exportaciones. El ramo textil mexicano ha logrado exportar 4.695 millones de dólares, ubicándose como el quinto proveedor a nivel mundial, y ha logrado ser el tercer generador más importante del PIB (Saucedo, 2013).

El 60% de las exportaciones totales textiles del país se destinan a EUA. Esta proporción es más alta en prendas de vestir (91.8%) donde existe mayor protección de EUA contra importaciones asiáticas. El segundo mercado en importancia es el resto de los países del Continente Americano, donde se analiza el 22% de las exportaciones mexicanas de este sector. En esta región México tiene celebrados tratados de libre comercio con Nicaragua, Costa Rica, Venezuela, Colombia, Bolivia y Chile. El 18% de las exportaciones de la cadena se destina a países de fuera del continente (Duarte & Arias, 2015).

La actividad económica del país e impacta inevitablemente a sus proveedores y sus subcontratistas, en su mayoría Pymes que se ven impuestas a adoptar los criterios internacionales de negocios internacionales de mayor tamaño.

En la ciudad de Moroleón ubicada al sur de Guanajuato se encuentran alrededor de 2000 PYMES registradas, estas se han convertido en el principal centro de producción y comercialización textil de la región (Ortiz & Hernández, 2017). A partir del análisis del desarrollo de la industria del suéter en Moroleón, Guanajuato, forma parte de una red de pequeñas ciudades industriales del occidente de México (Martínez & Gordillo, 2010). El caso de estudio se centra en la empresa “Textiles Renato”, dedicada a la fabricación de ropa de tejido de punto, la cual es una estructura básica realizada con una fontura de agujas en una máquina rectilínea. La principal característica de esta estructura es que el derecho y el revés de la tela son fácilmente reconocibles. Otras características de este tejido son su facilidad de estirarse tanto vertical como horizontalmente, su finura y su bajo peso. Desventajas: Si se rompe una puntada, el tejido se corre fácilmente, el tejido tiende a su vez a enrullarse los orillos; hacia el envés en los laterales y hacia el haz en las orillas superior e inferior (Niño & De la Valle, 2018) En el proceso de corte se cuenta con un molde con medidas y pesos estándar, de acuerdo con la talla que se le va a realizar el proceso de cortado, se posiciona el molde sobre el lienzo para dibujar el área a cortar, después de que se realiza el cortado, se tiene un desperdicio, el cual se pesa en una báscula y se registra el valor de este desperdicio, el objetivo del proyecto es aplicar el clasificador de redes neuronales y de los vecinos más cercanos para realizar la clasificación de sí un suéter de talla grande en n el proceso de corte, tiene una calidad eficiente o no, que se determina por medio de 6 características.

El objetivo principal de este Artículo, es realizar una clasificación de la calidad en el proceso de corte en el textil, por medio de dos clasificadores distintos, lo que nos permiten el monitoreo y clasificación para futuras prendas, lo que implica que el empresario preste mayor atención a la calidad, llevándolo a un mayor control del proceso productivo.

## 2. MARCO CONCEPTUAL

En esta sección se presentan los resultados de una búsqueda relevante de investigaciones con aplicaciones de la función del sector textil con redes neuronales y el algoritmo de los K- Vecinos.

El trabajo presentado por Zabala *et al.* (2018) realizaron por medio de una RNA de retro propagación de 3 capas, que genera formulaciones de color para productos textiles a partir de coordenadas de color  $L, a^*, b^*$  proporcionadas por un colorímetro. El coeficiente de determinación R total obtenido por la RNA propuesta fue de 0.99776 obteniendo un medio cuadrado del error de 0.0016 y 0.0019 en mililitros respectivamente para los colorantes empleados. Otro trabajo relevante fue presentado por Hoyos (2020), describe un servicio web realizado por guane Enterprise basado en visión por computadora, que permite la inferencia del tipo de defecto y la ubicación de este. El sistema fue entrenado sobre el conjunto de datos texUAN, recopilado por la Universidad Antonio Nariño que contiene alrededor de 2000 imágenes de telas que no tienen estampados ni adiciones de color. Con esta base de datos se entrenó un modelo en Google Cloud Platform usando el servicio AutoML Vision el cual arrojó una precisión del 89.89%.

Otro enfoque presentado por Amor, Nonam & Petru (2021), este artículo se centra en la clasificación de diversos problemas en los procesos textiles y compuestos poliméricos reforzados con fibra por RNA, algoritmo genético y lógica difusa. Además, también se presentan sus limitaciones asociadas con los procesos más avanzados y algunos métodos de clasificación secuenciales relativamente nuevos. En la investigación generada por Alvarado (2016), se presenta la utilización de técnicas espaciales de análisis de textura en imágenes para la identificación de defectos en textiles, en donde se aplican técnicas de pre-procesamiento, y para el análisis de textura los patrones locales binarios y la matriz de co-ocurrencia con fin de extraer características, resaltar las diferencias e identificar los defectos en los productos haciendo uso del clasificador basado en la distancia de mahalanobis.

### 2.1 MARCO TEÓRICO

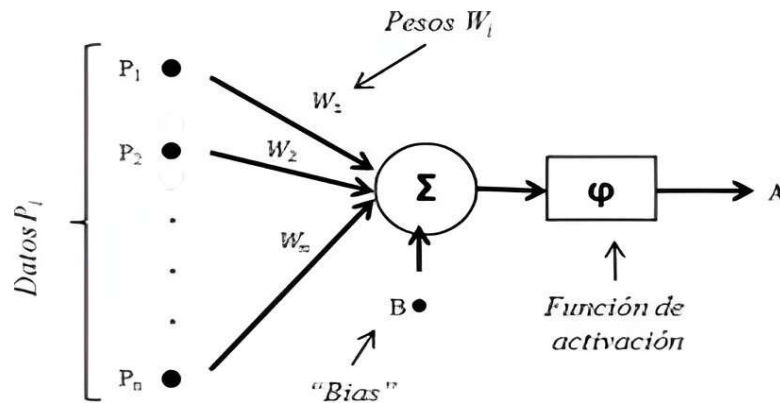
#### A. Redes Neuronales

En esta sección se presentan los conceptos que integran la teoría referente a las redes neuronales artificiales (RNA) y el algoritmo de los vecinos más cercanos. En este sentido y tal como lo plantea Cruz y Corrêa (2017), los elementos básicos de una neurona artificial son 6 como se muestran la la figura 1:

- i) conjunto de datos  $P_i$ , representando información de entrada
- ii) pesos  $W_i$ , asociada a cada entrada representando la sinapsis entre neuronas, elemento que permite la modulación de la intensidad de la señal de entrada;
- iii) sumatoria de todas las señales de entrada ponderadas por sus pesos sinápticos;
- iv) una función  $\varphi$  de transferencia o activación que permite limitar la amplitud de la señal de salida de una neurona a un valor finito;
- v) sesgo  $B$  (*bias*) un factor externo que permite aumentar o disminuir el valor de la entrada neta de la función de activación;


vi) salida ( $A$ ), respuesta de la RNA.

**Figura 1.**  
Estructura de una RNA (Basheer & Hajmeer, 2000).



Existen diversas funciones de activación que se pueden asociar a la neurona, entre ellas destaca la función de activación de escalón como se muestra en la figura 2, representada por:

**Figura 2.**  
Función de activación de escalón (Flores & Fernández, 2008).



Por otro lado, El comportamiento de una neurona puede ser expresada con la siguiente ecuación (Carbajal *et al.*, 2017):

$$S_i = \sum_{j=1}^n y_j w_{ij} + b_i \quad (1)$$

Donde:  $w_{ij}$  son los pesos que interconectan a las diferentes neuronas,  $j$  de la capa anterior con la neurona actual  $i$ ;  $b_i$  el sesgo de cada neurona;  $y_j$  la salida de la neurona de la capa anterior, y  $S_i$  es la nueva salida de la RNA.

La regla de aprendizaje del perceptrón es la popular regla delta. En la expresión el valor de la regla de aprendizaje  $\Delta w_{ij}(t)$ , es decir,  $\propto [D_j - O_j] I_j$ , es el resultado del modelo que establece el

cambio experimentado por los pesos como proporcional al gradiente del error  $E$  (Lahoz- Beltrá, 2004). Véase ecuación (2).

$$w_{ij}(t+1) = w_{ij}(t) + \alpha [D_j - O_j] I_j \quad (2)$$

La entrada neta es la suma del producto de cada señal que recibe de las neuronas de la capa anterior por el valor del peso que conecta ambas neuronas, menos el umbral de la neurona (Pol, Moreno & Far, 2000), como se muestra a continuación en la ecuación (3).

$$net_j = \sum_{i=1}^n w_{ij} x_i - \theta_j \quad (3)$$

La regla de actualización de pesos resulta ser [17]

$$w_{ij}^{new} = w_{ij}^{old} + \Delta_{ij}^r \quad (4)$$

La determinación de los términos de error para todas las neuronas se calcula (Larranaga, Inza & Moujahid, 1997): Cálculo del error (salida deseada– salida obtenida). Ecuación (5).

$$e = d_{pk} - y_{pk} \quad (5)$$

## B. K- Means

K-means es un algoritmo de clasificación no supervisada (clusterización) que agrupa objetos en  $k$  grupos basándose en sus características. El agrupamiento se realiza minimizando la suma de distancias entre cada objeto y el centroide de su grupo o cluster. Se suele usar la distancia cuadrática. El algoritmo consta de tres pasos a saber:

- i) Inicialización: una vez escogido el número de grupos  $k$ , se establecen  $k$  centroides en el espacio de los datos, por ejemplo, escogiéndolos aleatoriamente.
- ii) Asignación objetos a los centroides: cada objeto de los datos es asignado a su centroide más cercano.
- iii) Actualización centroides: se actualiza la posición del centroide de cada grupo tomando como nuevo centroide la posición del promedio de los objetos pertenecientes a dicho grupo.

Se repiten los pasos 2 y 3 hasta que los centroides no se mueven, o se mueven por debajo de una distancia umbral en cada paso.

El algoritmo k-means resuelve un problema de optimización, siendo la función por optimizar (minimizar) la suma de las distancias cuadráticas de cada objeto al centroide de su clúster (Mitchell & Mitchell, 1997).

Los objetos se representan con vectores reales de dos dimensiones  $(x_1, x_2, \dots, x_n)$  y el algoritmo k-means construye  $k$  grupos donde se minimiza la suma de distancias de los objetos, dentro de cada grupo  $S = \{S_1, S_2, \dots, S_k\}$ , a su centroide. El problema se puede formular como se plantea a continuación. Ecuación 6.

(6)

$$\min_s E(\mu_i) = \min_s \sum_{i=1}^k \sum_{x_j \in S_i} |x_j - \mu_i|^2$$

Donde  $SS$  es el conjunto de datos cuyos elementos son los objetos representados por vectores, donde cada uno de sus elementos representa una característica o atributo. Tendremos  $k$  grupos o clusters con su correspondiente centroide  $\mu_i$ . En cada actualización de los centroides, desde el punto de vista matemático, imponemos la condición necesaria de extremo a la función  $E(\mu_i)$  que, para la función cuadrática es, ecuación 7:

$$\frac{\partial E}{\partial \mu_i} = 0 \Rightarrow \mu_i^{(t+1)} = \frac{1}{|S_i^{(t)}|} \sum_{x_j \in S_i^{(t)}} x_j \quad (7)$$

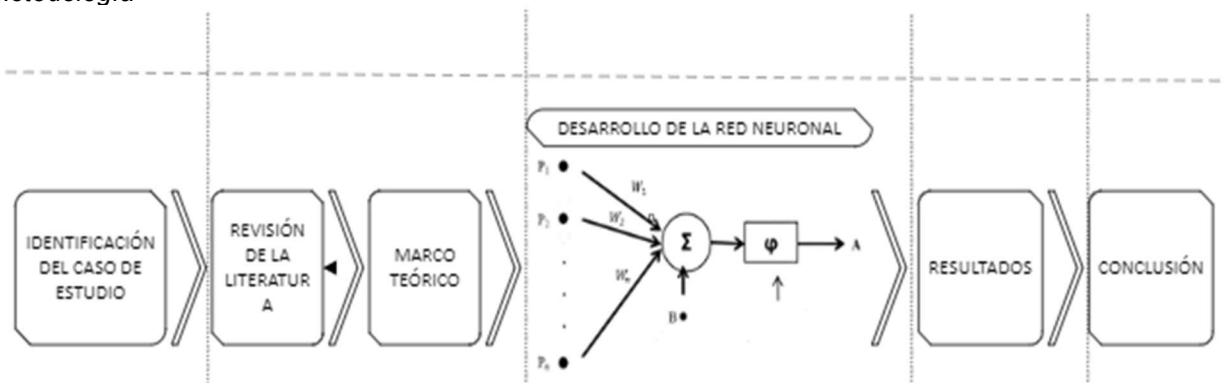
y se toma el promedio de los elementos de cada grupo como nuevo centroide.

Las principales ventajas del método *k-means* son que es un método sencillo y rápido. Pero es necesario decidir el valor de  $k$  y el resultado final depende de la inicialización de los centroides. En principio no converge al mínimo global sino a un mínimo local (Jahwar & Abdulazeez, 2020).

### 3. MATERIALES Y MÉTODOS

En esta sección se presenta la metodología diseñada para la realización de la investigación. Se desarrolla en seis etapas: identificación del caso de estudio, revisión de la literatura, marco teórico, desarrollo de la red neuronal artificial y vecinos más cercanos, resultados y conclusión como se muestra en la figura 3.

**Figura 3.**  
Metodología



Fuente: Propia Autoría

#### A. Identificación del caso de estudio

Se seleccionó a la PyME "Renatos" como caso de estudio para la realización de esta investigación. Se recolectó información del proceso de corte de una camiseta talla grande, se extraen 6 características, del cuerpo se toman: el largo, ancho y desperdicio producido, de igual manera para las mangas se toman las mismas características, se tienen 100 datos clasificados en una calidad buena o eficiente del proceso o una eficiencia mala en el proceso de corte. La distribución de las mediciones se asignó 70 mediciones para entrenamiento del clasificador K-

Medias, 15 de validación y 15 de prueba.

#### B. Revisión de la literatura

Análisis de las diferentes aplicaciones de redes neuronales, algoritmo de los K vecinos y aplicaciones en el sector textil que servirán como base para el desarrollo de la investigación desarrollada.

#### C. Marco Teórico

Durante esta etapa se conforma del marco conceptual del conocimiento necesario para dar soporte a la implementación propuesta, proporcionando el significado de los conceptos básicos utilizados apoyados en la literatura

#### D. Desarrollo de clasificadores.

Desarrollo de la clasificación por medio de dos clasificadores distintos, a saber, el primero de redes neuronales y el segundo de los K-vecinos, los dos implementados en el lenguaje de programación de Matlab. Las características son que se tuvieron en cuenta fueron: largo, ancho y desperdicio del cuerpo e iguales características se tuvieron en cuenta para las mangas. Los resultados para cada una de las características evaluadas en los cortes (cuerpo y mangas) se muestra en la tabla 1.

**Tabla 1.**

*Cuerpo y mangas*

LC	AC	DC	LM	AM	DM
43	16,2	2,03	40	13	3,3
49	17,5	48,81	46,5	13,9	15,5

Fuente. Propia Autoría.

#### E. Resultados.

Se tienen las simulaciones por medio de redes neuronales y el algoritmo de los vecinos más cercanos y se analiza e interpreta los resultados con el fin de lograr establecer cuál de los dos algoritmos es el más eficiente para la aplicación.

#### A. Conclusiones

A partir de los resultados se concluye el algoritmo más eficiente para la aplicación y se destaca lo más importante con el desarrollo de este proyecto y de las mejoras que se pueden tener para trabajos futuros.

## 4. RESULTADOS Y DISCUSIÓN

### 4.1. Redes Neuronales

Se eligió el valor del error cuadrático medio (MSE). Cuanto menor sea el valor, mejor será el ajuste del modelo. Primero, Se realizó una evaluación con el algoritmo de aprendizaje Scaled Conjugate Gradient. Se tiene una función de transferencia no lineal. Se variaron el número de



neuronas obteniendo los siguientes resultados. Estos resultados se presentan a continuación en la tabla 2.

**Tabla 2.**  
*Influencia del número de neuronas en la capa oculta*


# Neuronas	MSE	TrainingTime(s)	Epoch (s)
3	0.0000006224	11	26
4	0.0000004186	5	9
5	0.0000883	2	7
6	0.00016311	9	5
7	0.0000163895	2	4
8	0.000013287	2	8
9	0.000013913	8	43

Fuente: propia Autoría.

Como se puede observar el mejor desempeño del modelo en términos de MSE promedio y tiempo de entrenamiento se da con 4 neuronas en la capa oculta, con un MSE de 0.0000004186 para los 5 entrenamientos y un tiempo de entrenamiento de 5 segundos.

La estructura de la red con mejor rendimiento es la que se muestra a continuación en la figura 5.

**Figura 5.**  
*Estructura con mejor rendimiento*



Fuente: propia Autoría.

Los resultados obtenidos en las pruebas de clasificación se presentan en la figura 6, para entrenamiento, validación y prueba, respectivamente. Cada una de estas tablas se originó de las matrices de confusión correspondientes.

Se observa que 0 datos fueron clasificados incorrectamente en la etapa de entrenamiento de la RNA. En la etapa de validación, cero datos se clasificaron erróneamente y, en la etapa de prueba, la clasificación hubo 0 errores. Con estos resultados, tenemos un total de 0 muestras mal clasificadas y 100 muestras clasificadas correctamente, lo que da una tasa de éxito total del 100%.



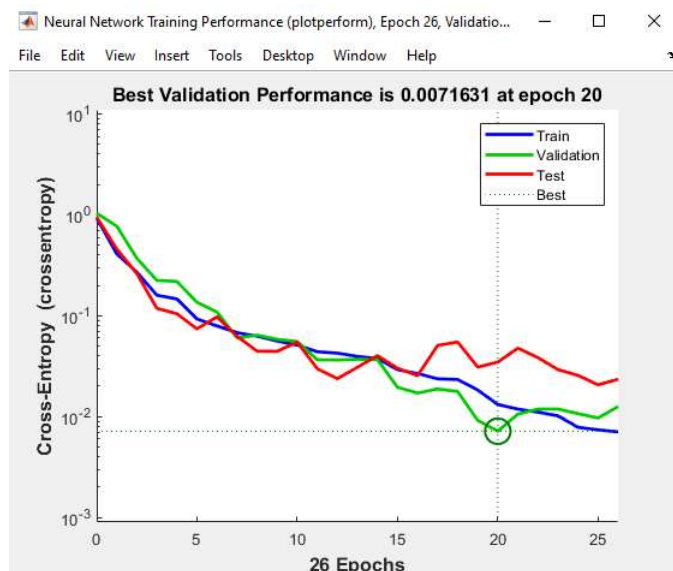
**Figura 6.**  
Matriz de confusión con 6 entradas y 4 neuronas en la capa oculta.



Fuente: propia Autoría.

En la figura 7 se muestra la gráfica el rendimiento de la RNA, en términos de error cuadrático medio para los ítems entrenamiento, validación y testeo.

**Figura 7.**  
Matriz de confusión con 6 entradas y 4 neuronas en la capa oculta, en una de las simulaciones.



Fuente: propia Autoría.

## 4.2 Algoritmo K-means

Para el algoritmo k medias se implementó un algoritmo en Matlab, en el que se realiza para diferentes tipos de K y se obtienen las siguientes eficiencias y resultados a la hora de realizarla clasificación, se realizaron 20 simulaciones para los diferentes valores de K, vale aclarar que los datos fueron elegidos de manera aleatoria, obteniendo los resultados que se presentan en la tabla 3.

**Tabla 3.**  
*Resultados de clasificación para diferentes valores de K.*

Iteraciones	K = 1	K = 2	K = 3	K = 4	K = 5
1	0.8	0.6	0.95	0.8	0.9
2	0.65	0.8	0.8	0.5	0.7
3	0.75	0.3	0.95	0.95	0.8
4	0.65	0.45	0.85	0.65	0.65
5	0.7	0.7	0.9	0.3	0.4
6	0.95	0.9	0.95	0.85	0.95
7	0.95	0.55	0.55	0.7	0.85
8	0.3	0.65	1	0.85	0.85
9	0.4	0.8	0.85	0.9	0.2
10	0.35	0.5	0.75	0.75	0.55
11	0.85	0.2	0.9	0.85	0.85
12	0.55	0.1	0.7	0.8	0.6
13	0.9	0.5	0.95	0.5	0.95
14	0.65	0.35	0.7	0.6	1
15	0.1	0.75	0.85	0.95	0.9
16	0.55	0.5	0.95	0.4	0.65
17	0.9	0.9	0.3	0.3	1
18	0.55	0.95	0.9	0.3	0.6
19	0.7	0.25	0.95	0.95	0.95
20	0.75	0.5	0.8	0.7	0.6
<b>Promedio</b>	<b>0.65</b>	<b>0.5625</b>	<b>0.8275</b>	<b>0.68</b>	<b>0.7475</b>

Fuente: propia Autoría.

Como se puede apreciar el mejor promedio de eficiencia se da para  $K = 3$ , con un porcentaje de clasificación promedio de 82,75%, el cual es poco eficiente si se compara con los resultados obtenidos por el modelo de RNA el cual fue del 100%.

## 5. CONCLUSIONES

El presente artículo, tiene un enfoque para la evaluación de dos clases de modelos de clasificación (RNA y K-means) en el proceso de corte de una Pyme del sector textil. Una cuando es eficiente y otra cuando no lo es. Se evaluaron 6 características importantes en el proceso de corte como son, en el cuerpo largo, ancho y desperdicio, y para el de las mangas se extraen las mismas características para su clasificación. Teniendo las 6 características se desarrollaron por medio de dos clasificadores el de RNA y de los K vecinos. Los mejores resultados en el modelo de RNA se obtuvo con el modelo de 4 neuronas en la capa ocupa el cual tuvo una eficiencia de clasificación del 100%, mientras que el modelo de clasificación K-means presento una

diferencia promedio de 82.5%, lo cual es una diferencia significativa que nos lleva a concluir que el modelo de RNA tiene un mejor desempeño respecto del modelo K-means.

El estudio realizado proporciona una herramienta práctica para ayudar que los trabajadores y los tomadores de decisión organizacionales evalúen los resultados obtenidos en el proceso de corte con el fin de mejorar la calidad y un ahorro significativo de dinero y recursos.

## REFERENCIAS

- Alvarado Moreno, J. D. (2016). Detección de defectos en textiles mediante técnicas espaciales para análisis de textura. *Tecnura*, 20(47), 97-106.
- Amor, N., Noman, M. T., & Petru, M. (2021). Classification of textile polymer composites: Recent trends and challenges. *Polymers*, 13(16), 2592.
- Basheer, I. A., & Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. *Journal of microbiological methods*, 43(1), 3-31.
- Carbajal-Hernández, J. J., Sánchez-Fernández, L. P., Hernández-Bautista, I., & Hernández-López, J. (2017). Modelo basado en redes neuronales artificiales para la evaluación de la calidad del agua en sistemas de cultivo extensivo de camarón. *Tecnología y ciencias del agua*, 8(5), 71-89.
- Consultivo, A. C. (2007). La innovación en el sector textil-confección de la Comunidad Valenciana. Alto Consejo Consultivo de la Comunidad Valenciana, IMPIVA, 209.
- Cruz, R. S., & Corrêa, C. (2017). Previsión de demanda intermitente con métodos de series de tiempo y redes neuronales artificiales: Estudio de caso. *Dyna*, 84(203), 9-16.
- Cruz-Beltrán, L. A., & Acevedo-Mosqueda, M. A. (2009). Aplicación del Reconocimiento de Voz de un Hablante Mediante una Red Neuronal Artificial Backpropagation y Coeficientes LPC sobre un canal Telefónico. *Programación Matemática y Software*.
- Duarte Arias, A. F., & Orozco Ahumada, C. F. Aplicación de un algoritmo genético que incorpora lógica difusa para la minimización del tiempo del proceso de corte de diferentes tipos de materia prima para la empresa Confecciones Taller 84.
- Flórez, R., & Fernández, J. (2008). Las redes neuronales artificiales, fundamentos teóricos y aplicaciones prácticas. España, Netbiblo.
- Hoyos Montes, Y. A. (2020). Detección de defectos en fibras textiles utilizando algoritmos de Deep Learning.
- Jahwar, A. F., & Abdulazeez, A. M. (2020). Meta-heuristic algorithms for K-means clustering: A review. *PalArch's Journal of Archaeology of Egypt/Egyptology*, 17(7), 12002-12020.
- Lahoz-Beltrá, R. B. Simulación, Vida Artificial e Inteligencia Artificial; Ediciones Díaz de Santos: Madrid, Spain, 2004. Google Scholar, 237-323.
- Larranaga, P., Inza, I., & Moujahid, A. (1997). Tema 8. redes neuronales. *Redes Neuronales*, U. del P. Vasco, 12, 17.
- Martínez, A., & Gordillo, E. (2010). Moroleón, sus inicios... Y 200 años de laboriosidad compartida. Colección Monografías Municipales de Guanajuato. Recuperado de: [http://cronistasdeguanajuato.com/assets/monografias/moroleon\\_opt.pdf](http://cronistasdeguanajuato.com/assets/monografias/moroleon_opt.pdf).
- Mitchell, T. M., & Mitchell, T. M. (1997). *Machine learning* (Vol. 1, No. 9). New York: McGraw-hill.
- Niño Montoya, L. F., & De Lavalley Yepes, C. (2018). Estudio de viabilidad para la creación de una empresa textil de ropa infantil en la ciudad de Medellín.
- Ortiz, M. A. B., & Hernández, A. O. (2017). Sector exportador de Guanajuato-textiles. *Jovenes en la Ciencia*, 3(2), 1345-1349.
- Pol, A. P., Moreno, J. M., & Far, A. C. (2000). Predicción del consumo de éxtasis a partir de redes neuronales artificiales. *Adicciones*, 12(1), 29-41.
- Saucedo, O. (2013). La industria textil en México: TLCAN, China y la globalización. Un análisis a favor de la estrategia de desarrollo integral. Recuperado de <https://www.anahuac.mx/mexico/files/investigacion/2013/may-jun/29.pdf>.

---

Zavala Ortiz, L. D. D. J., Vázquez López, J. A., Gutiérrez Rosas, P. T., & Tapia Esquivas, M. (2018). Generación de la formulación de color en un producto textil mediante redes neuronales artificiales. *Nova scientia*, 10(21), 78-96.

Los autores del trabajo autorizan a la Universidad Internacional de Ciencia y Tecnología (UNICYT) a publicar este resumen en extenso en las Actas del Congreso IDI-UNICYT 2024 en Acceso Abierto (Open Access) en formato digital (PDF) e integrarlos en diversas plataformas online bajo la licencia CC: Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0) <https://creativecommons.org/licenses/by-nc-sa/4.0/>.

La Universidad Internacional de Ciencia y Tecnología y los miembros del Comité Organizador del Congreso IDI-UNICYT 2024 no son responsables del contenido ni de las implicaciones de lo expresado en este artículo.