

**METODOLOGÍA PARA LA DETECCIÓN DE TELAS EN LA INDUSTRIA TEXTIL  
UTILIZANDO CÁMARAS**

**JULIANA SERNA LÓPEZ**

Proyecto de grado presentado como requisito parcial  
para aspirar al título de Ingeniero Electrónico

Director

M.Sc. Andrés Felipe Calvo Salcedo

**UNIVERSIDAD TECNOLÓGICA DE PEREIRA  
PROGRAMA DE INGENIERÍA ELECTRÓNICA  
PEREIRA**

**2017**

<b>Tabla de Contenido</b>	<b>Pag.</b>
1. INTRODUCCIÓN.....	4
1.1. PLANTEAMIENTO DEL PROBLEMA.....	6
1.2. OBJETIVOS.....	9
1.2.1. OBJETIVO GENERAL .....	9
1.2.2. OBJETIVOS ESPECÍFICOS .....	9
2. MARCO TEÓRICO .....	10
2.1. Conversión a escala de Grises .....	10
2.2. Transformada Rápida de Fourier ( <i>FFT- Fast Fourier Transform</i> ) .....	11
2.3. Adaptación de la Transformada corta en tiempo de Fourier para imágenes ( <i>Short-time Fourier transform-STFT</i> ): .....	12
2.4. Transformada discreta Wavelet.....	13
2.5. Transformada discreta Wavelet en dos dimensiones.....	15
2.6. Descriptor SFTA (Segmentation-based Fractal Texture Analysis).....	17
2.7. Descomposición binaria de dos umbrales (Two-Threshold Binary Decomposition -TTBD). 17	17
3. METODOLOGÍA .....	19
3.1. Construcción Base de Datos anotada: .....	19
3.2. Extracción de Características .....	20
3.3. Descriptor FFT .....	21
3.4. Descriptor STFT.....	21
3.5. Descriptor Wavelet.....	22
3.6. Descriptor STFA .....	22
3.7. Entrenamiento y validación del modelo de clasificación .....	23
4. RESULTADOS .....	25
5. CONCLUSIONES .....	35
6. REFERENCIAS .....	36

## Índice de figuras

FIGURA 1. TELA EN RGB A ESCALA DE GRISES.....	11
FIGURA 2. EJEMPLO DE LA STFT .....	13
FIGURA 3. TRANSFORMADA WAVELET. ....	14
FIGURA 4. DESCOMPOSICIÓN DE UN NIVEL DE LA 2D-DWT [10]. ....	16
FIGURA 5. DESCOMPOSICIÓN DE UNA IMAGEN CON LA 2D-DWT EN SUS CUATRO COMPONENTES (LL, LH, HL, HH) [10].....	16
FIGURA 6. DESCOMPOSICIÓN DE UNA IMAGEN SATELITAL UTILIZANDO EL ALGORITMO TTBD. EL CONJUNTO RESULTANTE DE IMÁGENES BINARIAS SE OBTUVO UTILIZANDO $N T = 8$ . ....	18
FIGURA 7. METODOLOGÍA PROPUESTA.....	19
FIGURA 8. BASE DE DATOS ANOTADA DE TELAS TEXTILES .....	20

## Índice de tablas

TABLA 1. TABLA DE DESCRIPTORES PARA REALIZAR LOS CÁLCULOS ANTERIORES SE OBTIENE EL VECTOR DE CARACTERÍSTICAS FFT CON DIMENSIONES 4X1. ....	21
TABLA 2. MATRIZ DE CONFUSIÓN MÉTODO FFT-SVM .....	26
TABLA 3. MATRIZ DE CONFUSIÓN MÉTODO STFT-SVM .....	27
TABLA 4. MATRIZ DE CONFUSIÓN MÉTODO WAVELET-SVM .....	28
TABLA 5. MATRIZ DE CONFUSIÓN MÉTODO SFTA-SVM.....	29
TABLA 6. MATRIZ DE CONFUSIÓN MÉTODO FFT-RNA.....	30
TABLA 7. MATRIZ DE CONFUSIÓN MÉTODO STFT-RNA .....	31
TABLA 8. MATRIZ DE CONFUSIÓN MÉTODO WAVELET-RNA .....	32
TABLA 9. MATRIZ DE CONFUSIÓN MÉTODO STFA-RNA.....	33
TABLA 10. DESEMPEÑO PROMEDIO DE METODOLOGÍAS PARA IDENTIFICACIÓN DE TELAS UTILIZANDO DESCRIPTORES DE TEXTURA .....	33

## 1. INTRODUCCIÓN

Con el alto crecimiento de la industria textil, y con su gran participación en el comercio y la economía del país y del mundo, se exige que con el mejoramiento de las tecnologías y de la ciencia, se avance también en la tecnología que manejan las telas, por esto en cuanto a nuevas telas se implementan fibras que cada vez ofrecen mayores beneficios en diferentes campos, como son las telas que se usan para la ropa deportiva, o para crear trajes de protección industrial, entre muchas otras cosas; también con el cambio climático y la preocupación que esto trae alrededor del mundo, los esfuerzos en la creación de telas que puedan proteger a las personas de los rayos UV del sol, o del frío crecen, ofreciendo cada día mejoras en las fibras y calidades de las telas.

Por esto el proceso de clasificación de telas es una tarea que no se puede dejar al azar, y aprovechando tecnologías como las técnicas de visión por computador, en donde maquinas realizan estos procesos de manera eficiente, y representan también un bajo costo para la industria textil, el uso de estas herramientas va en aumento; por ende la demanda de desarrollo de algoritmos eficientes crece cada día, ya que estos todavía presentan falencias, el estudio no termina, y con el avance de los conocimientos en los diferentes campos que interfieren en el proceso de toma de datos y clasificación, como lo es el desarrollo electrónico que no para, y las nuevas tecnologías en cámaras, las mejoras crecen en igual proporción.

Siendo la industria textil una importante área de la economía de un país, ya que no solo genera empleos, sino también es una considerable fuente de ingresos, es importante conocer aspectos en los cuales esta pueda requerir mejoras aprovechando la tecnología creciente y la era digital en la que vivimos hoy en día, como lo es el proceso de clasificación de las telas [6]. En la industria textil manejan diferentes tipos de fibras en la fabricación de las telas, haciendo que estas sean totalmente diferentes entre ellas, a lo que llaman como tecnología textil [7], esto se hace para crear telas para diferentes propósitos como protección contra el frío, absorbentes de líquidos, o simplemente como adorno personal, entre otros, habiendo así telas que se clasifican por tener fibras naturales, o fibras sintéticas, y otros diferentes factores que determinan su calidad, siendo de esta manera, la tarea de clasificación de cada tipo de tela muy importante y algo que no se puede dejar al azar, por esto el desarrollo de algoritmos que las puedan clasificar de manera automática y eficiente, es algo que se ha venido buscando, haciendo uso de diferentes métodos,

empezando desde la clasificación que hacen los operarios con conocimientos previos de las telas, método que puede no resultar efectivo debido a que cada persona percibe los colores y las texturas de diferente manera, además de que existe una amplia variedad de materiales, dejándole esta tarea a las maquinas, que con algoritmos bien desarrollados, logran hacer el trabajo eficientemente y de manera efectiva.

Las técnicas de visión por computador se han estado usando para la clasificación de telas ya que la tecnología en sistemas electrónicos incrementan día a día, haciendo así que sus capacidades de procesamiento crezcan de igual manera, y haciendo el trabajo de analizar e interpretar imágenes de telas de forma automática más eficiente; además, usando este tipo de técnicas, el proceso de adquisición de datos lo hace una máquina eficazmente, y la identificación y clasificación de telas se realiza de forma automática sin importar el tipo de material del que está hecha. Con esto solo queda implementar un algoritmo de clasificación adecuado y bien desarrollado, por esto es importante hacer un amplio estudio de técnicas de descripción de imágenes que extraiga la mayor cantidad de características de cada una de las imágenes de las telas para que luego puedan ser procesadas, y también es necesario conocer los diferentes métodos de aprendizaje de maquina supervisado que, finalmente, serán los que realicen la clasificación.

Al momento de extraer las características de una imagen como el color, la forma o la silueta, con algún método automático, este suele ser susceptible a las condiciones fotométricas de la escena u oclusiones parciales o totales del objeto de estudio, por esto, para tener una metodología eficiente de reconocimiento y clasificación de imágenes se deben tener en cuenta los siguientes aspectos [8]:

- Crear representaciones de las imágenes de las telas con pocas diferencias entre estas que serán codificadas siendo siempre válidas para definir las transformadas geométricas relacionadas con el dominio.
- Estructurar e implementar algoritmos adecuados para representar los modelos de los objetos encontrados en las imágenes de manera eficiente.
- Implementar técnicas eficientes de agrupamiento, simetría y clasificación, que puedan mejorar los métodos de aprendizaje, reconocimiento y clasificación de las imágenes, por esto es que los conjuntos de entrenamiento deben ser pequeños y los métodos de aprendizaje adecuados para obtener un sistema de clasificación eficaz.

## 1.1. PLANTEAMIENTO DEL PROBLEMA

Ser ajeno al progreso de la sociedad es algo que no se debe permitir hoy día, y mucho menos cuando el sector industrial cada vez se vuelve más competitivo y exigente. La demanda de productos que se diversifican en múltiples sectores exige que a diario se cumplan con estándares que garanticen un mejor desempeño, funcionalidad y satisfacción, y más aún cuando se está frente a un mercado global el cual se fundamenta en tratados de libre comercio.

El control de calidad está definido, como la regulación del grado de conformidad del producto final con sus especificaciones. Esta especificación puede ser objetiva y formal, pero en fábricas de Tejido de punto, es a menudo subjetiva y difícil de definir. La discusión sobre el control de calidad debe empezar, pues, con una consideración de las propiedades objetivas del tejido que deben ser controladas, si es que se pretende tratar las especificaciones objetivas y subjetivas [1]; el número de estas propiedades es grande, pero puede dividirse en tres grupos:

- Las propiedades geométricas del artículo. Este grupo de propiedades incluye el tamaño de la malla, así como su variabilidad. El tamaño medio junto con el número del total de las mallas en las varias partes del género, determinan las dimensiones del artículo. Por otra parte, la variación del tamaño de la malla afecta el aspecto del artículo. El color del artículo puede considerarse como perteneciente a este grupo de propiedades. La conservación de estas propiedades durante el uso forma parte del segundo grupo, pero la conservación durante el mojado y secado, lavado o cualquier otro tratamiento con agua pertenecen a este grupo.
- Las propiedades mecánicas del artículo. Como su extensibilidad a la carga, la flexibilidad, no tienen interés en la clasificación cualitativa del artículo. Estas propiedades, no obstante, tienen importancia por cuanto juegan en la determinación de propiedades subjetivas, como el efecto calidad, suavidad y tupidez.
- Las propiedades retentivas comprenden un grupo relacionado con la posibilidad de que el artículo retenga sus características con el uso. Las más importantes son la resistencia a la abrasión, al pilling y la solidez del color.

El control de calidad es muy importante al momento de seleccionar la tela con la que se va a trabajar, y precisamente en este campo se presentan muchos errores, debido a que los operarios como personas que son, a lo largo del proceso pueden detectar algunas características como el color o la textura de la misma tela de diferentes, esto dependiendo de la hora en que la observe, las condiciones de luz, entre muchos otros factores que afectan la visión humana; y debido a la gran demanda nacional e internacional en cuanto a la producción de nuevas fibras, se ha incrementado de igual forma la demanda de personal capacitado para el cumplimiento y soporte de estas, por ende ,es realmente necesario crear nuevas herramientas tecnológicas que faciliten y permitan cumplir con las requerimientos de la industria. En este sentido, esta situación ha hecho que la producción se realice de una manera más eficiente y eficaz, para lograr cumplir con las metas establecidas, y en muchos de los casos se puede arriesgar la calidad del producto.

En Colombia, se realizan distintas investigaciones financiadas por el ministerio de comercio, industria y turismo, pero estas le apuestan al textil, debido a la preocupación que tienen los consumidores acerca del cambio climático, estudiando también, la manufactura de textiles y el control de calidad de este producto (tela) en los procesos de producción como fuente de ingreso y de qué manera afecta el sector económico. Determinar el tipo de telas de una manera automatizada es fundamental al manejar grandes masas, ya que un operario no puede realizar esta labor, debido a la diversidad y cantidad de telas, sin olvidar las otras funciones que tienen que cumplir. Aunque muchas metodologías han demostrado ser útiles para el reconocimiento de patrones, en los ambientes industriales no siempre se cuenta con la posibilidad de garantizar unas condiciones controladas de trabajo (iluminación, vibración, entre otros), bajo las cuales pueda operar el sistema de identificación [2]. Estas condiciones hacen que algunos descriptores no se adapten a diferentes situaciones [2 3]. Ejemplo de ello se evidencia con los descriptores de color, los cuales no son robustos a cambios de iluminación [4].

Es de resaltar el trabajo de grado “análisis comparativo de descriptores para la clasificación de telas utilizando imágenes” [5], en donde se utilizó una metodología destacable para la clasificación de telas, esta metodología consta básicamente de cuatro pasos fundamentales:

### 1. Captura de la base de datos.

Para la creación de la base de datos se toman 100 imágenes de cinco tipos de telas diferentes (lino, blonda, scuba, velo, acetato) para un total de 500 imágenes. Para esta labor se acondiciona un mono podo el cual se fija en una posición que garantiza una altura constante de 15cm respecto al objeto, de modo que se obtuviera una buena información a la hora de identificar las imágenes.

### 2. Extracción de las características.

Para obtener las características de la tela se usan distintas herramientas, como lo son las transformadas visualizadas en tiempo-frecuencias, ya que se utilizan descriptores como lo es, la representación paramétrica de la transformada de Fourier, ya que son métodos de confiabilidad para la obtención y reconstrucción de imágenes textiles. Además de la transformada rápida de Fourier (FFT), se utiliza la transformada de Fourier corta en el espacio (SSFT) y por último la transformada de Wavelet.

### 3. Algoritmo de aprendizaje de máquina

Para las transformaciones del punto anterior se calculan los momentos estadísticos con el fin de obtener los descriptores o características y poder realizar los dos métodos de aprendizaje de máquina supervisado (máquina de vectores soportado, redes de neurona artificiales).

### 4. Análisis estadístico

Por último, se realiza un análisis estadístico, combinando los distintos descriptores con los métodos de aprendizaje supervisado con el fin de determinar cuál es el mejor método para clasificar los cinco tipos de telas.

Tomando como base el trabajo de grado “análisis comparativo de descriptores para la clasificación de telas utilizando imágenes” [5], es de comprender que la base de datos de éste es muy pequeña, por consiguiente los márgenes de errores puede tender a crecer, sin embargo, los métodos estadísticos que en este se utilizan son buenos, pero falta validar mucha información, ya que no aplican otros métodos estadísticos adicionales como son la desviación estándar, moda, media, Kurtosis; como también no se lleva a cabo el método de Montecarlo, que puede servir como respaldo para validar la información obtenida por las imágenes.

## **1.2. OBJETIVOS**

### **1.2.1. OBJETIVO GENERAL**

Realizar un análisis comparativo de descriptores en frecuencia y tiempo frecuencia para el control de calidad de 10 tipos de telas usando métodos de aprendizaje maquinas supervisado RNA (redes neuronales artificiales) y SVM (máquina de soporte vectorial).

### **1.2.2. OBJETIVOS ESPECÍFICOS**

- Crear una base de datos anotada de 10 diferentes tipos de telas.
- Definir los descriptores adecuados que permiten obtener las características de interés de cada uno de los tipos de telas que se van a trabajar.
- Definir los algoritmos de aprendizaje de maquina adecuados para la identificación de tipos de telas.
- Implementar y evaluar diferentes algoritmos de aprendizaje de máquina utilizando las características obtenidas.
- Validar estadísticamente el trabajo de clasificación.

## 2. MARCO TEÓRICO

El área de visión por computadora busca a través del procesamiento digital de señal proponer metodologías para el reconocimiento de patrones en una escena [1], es necesario conocer y utilizar métodos para el procesamiento de imágenes que se adecuen a la aplicación deseada que para este trabajo es el reconocimiento y discriminación de tipos de telas.

Teniendo en cuenta que, a la hora de construir una tela, el bordado del hilo del sigue patrones diferentes dependiendo de la tela, se podría aprovechar esta característica para observar la variación espacial de estos patrones por lo que la literatura propone usar técnicas de análisis de señales como la transformada rápida de Fourier, y la transformada wavelet, entre otras.

### 2.1. Conversión a escala de Grises

Generalmente los algoritmos de Textura no requieren de un análisis por color, por lo cual es necesario realizar una conversión a escala de grises con el objetivo de reducir el tiempo de cómputo. Esto se debe a que la información de estos métodos se encuentra en la variación espacial de intensidades del pixel.

Para realizar la conversión a escala de grises se utiliza la siguiente función de transformación:

$$I_g(x, y) = 0.2989 * R(x, y) + 0.5870 * G(x, y) + 0.1140 * B(x, y) \quad (1)$$

Donde, R, G y B son las canales de la imagen a color en espacio RGB.

En la figura 1, se puede observar el resultado de la conversión a escala de grises de un segmento de tela.

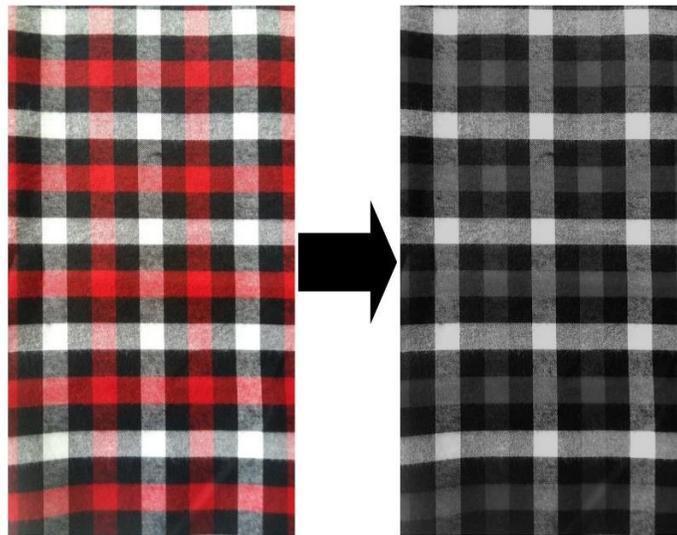


Figura 1. Tela en RGB a escala de grises.

Para hacer esto se usa la función de Matlab *rgb2gray()*, que convierte cualquier imagen que esté en formato RGB a escala de grises o blanco y negro.

## 2.2. Transformada Rápida de Fourier (*FFT- Fast Fourier Transform*)

La transformada rápida de Fourier es un método matemático que permite la representación en frecuencia de las diferentes componentes de una señal discreta [2]. Esta representación permite determinar sus frecuencias, pero a costa de perder la información de tipo temporal, esto indica que se conoce que frecuencias tiene señal pero no en que momento aparecen.

Teniendo cada tela ofrece un patrón del hilo diferente, estas variaciones pueden caracterizarse según la componentes en frecuencia que aparezcan en cada tela. Esta transformada no contiene todas las frecuencias que forman una imagen, sino sólo un conjunto de muestras lo suficientemente grande para describir completamente la imagen del dominio espacial. El número de frecuencias corresponde al número de píxeles en la imagen, es decir que la imagen en el dominio espacial y Fourier son del mismo tamaño.

Para realizar el cálculo de la FFT se debe aplicar el siguiente modelo computacional:

$$F(u, v) = \frac{1}{nc*nf} \sum_{c=1}^{cn} \sum_{f=1}^{nf} I(c, f) * e^{-2\pi i * \left( \frac{u*c}{nc} + \frac{v*f}{nf} \right)} \quad (2)$$

Dónde:

nf es el número de filas

nc es el número de columnas

I(c,f) es la imagen en escala de grises

u es la coordenada espacial de fila en el espacio de Fourier

v es la coordenada espacial de columna en el espacio de Fourier

El resultado que se obtiene al aplicar el cálculo de la FFT (2) son variables complejas. Para el análisis, se debe calcular la magnitud de los datos aplicando la ecuación (3).

$$|F(u, v)| = \sqrt{[Re(u, v)]^2 + [Im(u, v)]^2} \quad (3)$$

Las funciones de base son ondas seno y coseno con frecuencias crecientes, es decir, F (0,0) representa la componente DC de la imagen que corresponde al brillo medio y F (nf-1, nc-1) representa la frecuencia más alta. La función en Matlab encargada de realizar la FFT, es fft().

### **2.3. Adaptación de la Transformada corta en tiempo de Fourier para imágenes (Short-time Fourier transform-STFT):**

Esta transformada es una variación metodológica de la FFT para garantizar obtener información frecuencia con respecto a la variación de tiempo [3]. Esta metodología no es un método de análisis directo para imágenes digitales debido a que fue creada para señales unidimensionales que varían con respecto al tiempo. Sin embargo las ventajas que ofrece este método para caracterizar variaciones de frecuencia en una señal temporal, puede ser extrapolado para caracterizar variaciones de frecuencia en con respecto a la variación espacial de la imagen.

Para realizar esta extrapolación, se toman pequeñas muestras de la imagen con dimensiones fijas, en este caso una ventana cuadrada, lo que permite determinar en pequeños intervalos espaciales los sucesos en frecuencia.

Para realizar este cálculo se aplica la siguiente función de transformación:

$$\mathbf{STFT}\{x[n]\} \equiv X(m, \omega) = \sum_{c=1}^{n_f} \sum_{f=1}^{n_f} F(u, v)\omega[n - m] \quad (4)$$

Donde en la Figura 2 se observa la aplicación de la STFT.

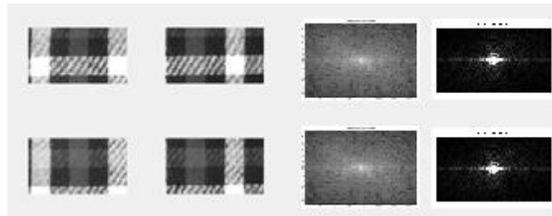


Figura 2. Ejemplo de la STFT

#### 2.4. Transformada discreta Wavelet.

La transformada Wavelet es un método de caracterización de señales que permite obtener una representación en función de cambios abruptos en sus componentes de tiempo-frecuencia de forma instantánea, esto se logra gracias al análisis de multiresolución con ventanas de longitud variable, las cuales dependen del cambio de frecuencia de la señal. Es decir, esta técnica permite el uso de intervalos grandes de tiempo en aquellos segmentos en los que se requiere mayor precisión en baja frecuencia, e intervalos más pequeños donde se requiere información en alta. Esto permite mejorar el análisis de la STFT la cual presenta una limitante en el tamaño fijo de la ventana espacial que impide analizar pequeños detalles en señales de frecuencia variable.

La transformada de wavelet no tiene como base funciones senos y cosenos, sino pequeñas funciones u ondas que se ubican en el tiempo y en la frecuencia de la señal, esto permite el análisis de señales que son transitorias y variables en el tiempo, como el comportamiento de las señales que proporcionan los hilos de las telas es desconocido, es necesario hacer un mapeo sobre toda la imagen, y para esto se usa la transformada discreta de wavelet DWT, que transforma este

mapeo en un conjunto finito de variables que pueden ser analizados con sumatorias, el mapeo es exponencial, es decir, que las ventanas que toma esta transformada para discretizar y analizar no son todas de la misma dimensión, sino que va creciendo exponencialmente, como se observa en la Figura 3.

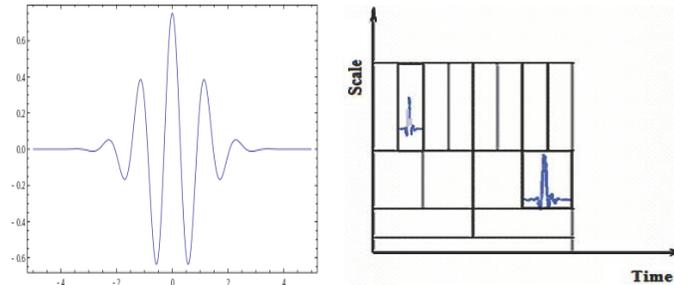


Figura 3. Transformada wavelet.

La transformada de Wavelet se halla con la correlación entre una función en el dominio del tiempo, y una wavelet madre, o usando el teorema de parseval, se puede tener una transformada de wavelet en el dominio de la frecuencia.

$$\Psi_{u,s}(t) = \int |f(t)|^2 dt \quad (5)$$

Ecuación. Wavelet madre.

$$f(u, s) = \int_{-\infty}^{\infty} f(t) \frac{1}{\sqrt{s}} \Psi\left(\frac{t-u}{s}\right) dt \quad (6)$$

Ecuación. Transformada wavelet en el tiempo.

$$f(u, s) = \int_{-\infty}^{\infty} \hat{f}(\omega) \sqrt{s} \hat{\Psi}^*(s\omega) e^{i\omega u} d\omega \quad (7)$$

Ecuación. Transformada wavelet en frecuencia.

Debido a que es posible encontrar grandes cambios en el tiempo, es necesario cambiar la forma de mapeo continuo que se hace sobre la señal, a un análisis de un conjunto de valores, esto es discretizar la señal, y de aquí surge la DWT (transformada discreta de wavelet), así es posible representar una función en el dominio del tiempo con una serie de sumatorias de funciones wavelet.

$$f(t) = \sum_k \sum_j C_{j,k} \Phi(t) + \sum_k \sum_j d_{j,k} \Psi(t) \quad (8)$$

Ecuación. Transformada discreta de wavelet.

La descomposición de la wavelet multiresolución en una dimensión, se puede extender fácilmente a dos dimensiones mediante la introducción de escala separable 2-D

## 2.5. Transformada discreta Wavelet en dos dimensiones.

Se observó que la transformada Wavelet permite caracterizar señales representando una función de cambios abruptos en los componentes en tiempo y frecuencia en una dimensión. Pero para aplicaciones en procesamientos de imágenes, se requiere la implementación de esta transformada pero en dos dimensiones.

La transformada de Wavelet para dos dimensiones (2-D DWT) de una función bidimensional de un tamaño  $M \times N$ , se representada por las siguientes ecuaciones [9]:

$$DWT_h(j_0, m, n) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} F(x, y) * h_{j_0, m, n}(x, y) \quad (9)$$

$$DWT_\psi^i(j, m, n) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} F(x, y) * \psi_{j, m, n}^i(x, y) \quad (10)$$

Dónde  $j_0$  es la escala de inicio arbitraria y los coeficientes  $DWT_h(j_0, m, n)$  definen la aproximación de la función en la escala  $j_0$ . Y los coeficientes  $DWT_\psi^i(j, m, n)$  suman los detalles horizontales, verticales y diagonales para la escala de  $j \geq j_0$ . Normalmente  $j_0$  es cero y  $N=M=2^j$  de tal manera de que  $j = 0, 1, 2, 3, \dots, J-1$  y  $m, n = 0, 1, 2, 3, \dots, 2^{j-1}$ .

El funcionamiento de esta transformada es de la siguiente manera: realiza la separación de las líneas de las columnas y realiza el mismo proceso de la DWT de una dimensión, considerando como señales unidimensionales a cada fila y columna. La figura 4, se muestra el proceso que se efectúa en una señal 2D para ser analizada como bancos de filtros para realizar la 2D-DWT.

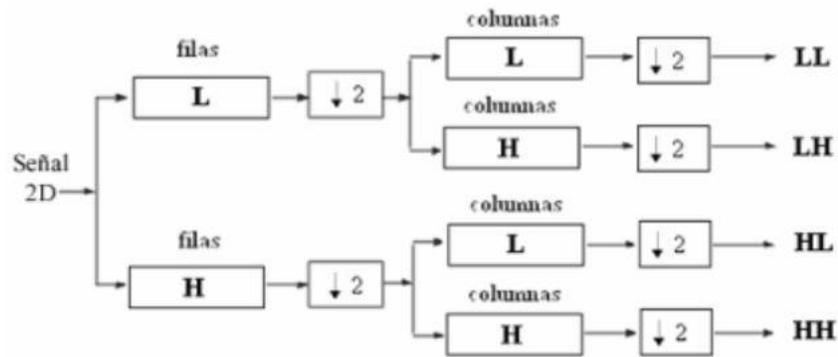


Figura 4. Descomposición de un nivel de la 2D-DWT [10].

Al observar la figura anterior, el primer paso es separar las filas y aplicar los filtros pasa-altos (H) y pasa-bajas (L) como se haría en la DWT de una dimensión. Después se realiza el mismo proceso para cada columna de la señal y genera 4 nuevas sub-matrices: aproximación LL, LH que son detalles horizontales, HL que son detalles verticales y la HH son detalles diagonales. Estas sub-matrices corresponden a la información de la señal en 2D. En la figura 5, se observa un ejemplo de primer nivel de descomposición de una imagen que genera las 4 sub-imágenes [10].

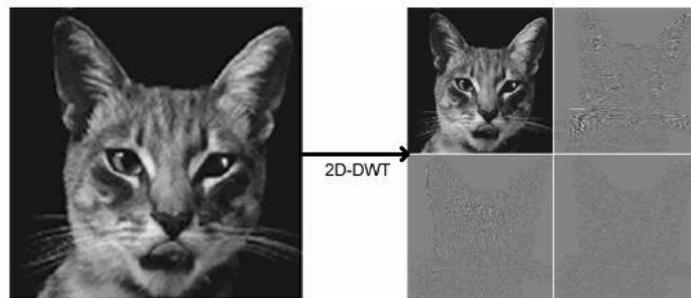


Figura 5. Descomposición de una imagen con la 2D-DWT en sus cuatro componentes (LL, LH, HL, HH) [10].

La función en Matlab que se encarga de hacer todo este proceso es `dwt2()`, y esta entrega 4 análisis, uno haciendo el mapeo sobre la imagen de forma horizontal, otro de forma vertical, otro de forma diagonal, y un último en amplitud.

## 2.6. Descriptor SFTA (Segmentation-based Fractal Texture Analysis)

El descriptor SFTA es un algoritmo de extracción de características que consiste en descomponer la imagen digital en un conjunto de imágenes binarias a partir de las cuales se calculan las dimensiones fractales de las regiones resultantes para describir patrones de textura segmentados.

En esta sección se explicará los modelos computaciones necesarios para realizar este cálculo. El algoritmo SFTA se puede dividir en dos partes principales: primero se descompone la imagen en escala de grises de entrada en un conjunto de imágenes binarias.

Para descomponer la imagen de entrada se emplea una nueva técnica denominada Descomposición Binaria de Dos Umbrales (TTBD), para cada imagen binaria resultante, se calcula la dimensión fractal y se calcula el nivel medio de las regiones y el tamaño en píxeles.

## 2.7. Descomposición binaria de dos umbrales (Two-Threshold Binary Decomposition -TTBD)

Este método toma como entrada una imagen en escala de grises  $I(x, y)$  y devuelve un conjunto de imágenes binarias. El primer paso de TTBD consiste en calcular un conjunto  $T$  de valores de umbral. Para el cálculo de los umbrales se utiliza el algoritmo multi-nivel Otsu [17]. El algoritmo de Otsu de varios niveles consiste en encontrar el umbral que minimiza la varianza dentro de la clase de la imagen. Entonces, de forma recursiva, el algoritmo de Otsu se aplica a cada región de imagen hasta que se obtiene el número deseado de umbrales  $n_t$ , donde  $n_t$  es un parámetro definido por el usuario.

El siguiente paso del algoritmo TTBD consiste en descomponer la imagen en escala de grises de entrada  $I(x, y)$  en un conjunto de imágenes binarias. Esto se consigue seleccionando pares de umbrales de  $T$  y aplicando una segmentación de dos umbrales como sigue:

$$I_b(x, y) = \begin{cases} 1, & t_l < I(x, y) \leq t_u \\ 0, & \text{en otro caso} \end{cases} \quad (11)$$

Donde  $t_l$  y  $t_u$  indican, respectivamente, valores de umbral inferior y superior.

El conjunto de imágenes binarias se obtiene aplicando el modelo anterior a la imagen de entrada. Por lo tanto, el número de imágenes binarias resultantes es  $2n$ . La Figura 6 ilustra la descomposición de una región tomada de una imagen de satélite utilizando el algoritmo TTBD. El conjunto resultante de imágenes binarias se obtuvo utilizando  $n = 8$ .

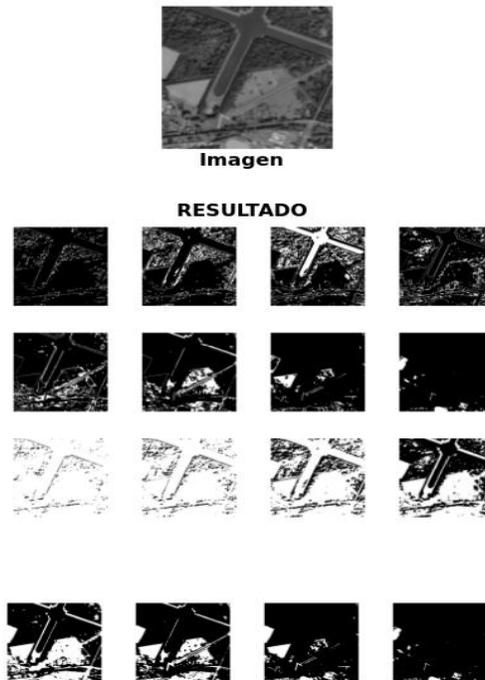


Figura 6. Descomposición de una imagen satelital utilizando el algoritmo TTBD. El conjunto resultante de imágenes binarias se obtuvo utilizando  $n = 8$ .

### 3. METODOLOGÍA

Siendo el objetivo principal de este trabajo el estudio de descriptores de textura con técnicas de aprendizaje supervisado para la detección automática de telas en la industria textil. En esta sección se propone una metodología estructurada que consta de tres etapas fundamentales que permiten evaluar el desempeño de cada método de aprendizaje con los diferentes métodos de caracterización. Inicialmente se realiza la construcción de una base de datos anotada con captura de imágenes de las diferentes tipos de telas textiles comerciales, posteriormente en una segunda etapa, se realiza la extracción de características basada en diferentes funciones de transformación espacio frecuencia (WAVELETH, FFT Y SFTF, SFTA) y por último, en la última etapa se plantea el entrenamiento y validación de modelos de clasificación utilizando SVM y RNA para determinar a qué clase pertenece cada observación permitiendo observar el desempeño de la método propuesto. En la figura 7, se observa el diagrama de bloques de la metodología aplicada a este trabajo.

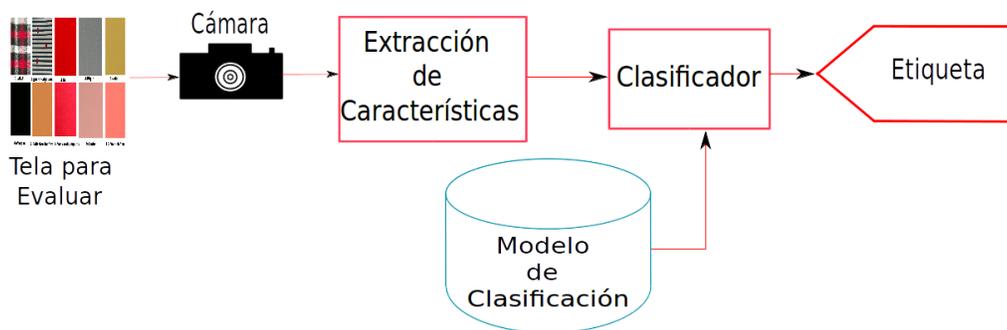


Figura 7. Metodología Propuesta

#### 3.1. Construcción Base de Datos anotada:

Para la captura de las imágenes, se utilizó un *smartphone* con cámara digital de resolución de 1080 x 1920. Siendo el objetivo principal de este trabajo evaluar descriptores de textura, se escogieron 10 telas comunes en ventas textiles y se garantizó diferentes patrones en el cosido. Lo anterior con el objetivo de verificar el aporte de cada descriptor. Para cada clase se capturaron

100 imágenes obteniendo total de 1000 fotos y se resalta que estas capturas se realizaron en diferentes momentos y sin un entorno controlado de iluminación.

En la figura 8 se puede observar las diferentes clases de telas de la base de datos anotada.

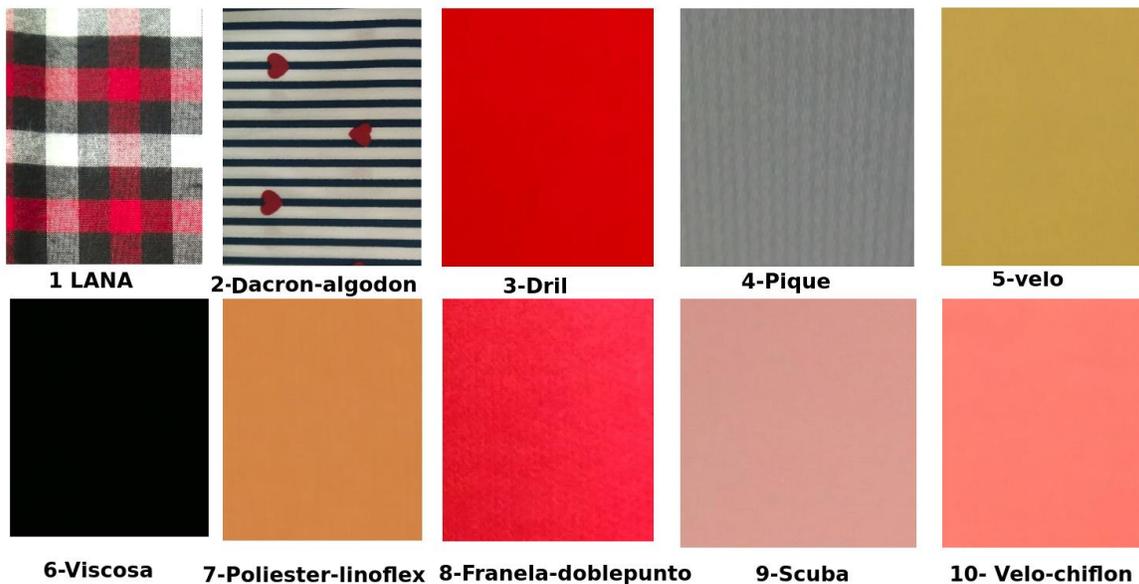


Figura 8. Base de datos anotada de telas textiles

### 3.2. Extracción de Características

Para mejorar la separabilidad de los datos provistos por la cámara, el estado del arte propone realizar una etapa de extracción de características. Para efectos de este trabajo se utilizaron cuatro descriptores espacio-frecuencia que tiene como objetivo caracterizar la textura de un producto textil y así evaluar su comportamiento con clasificación de aprendizaje supervisado. Los descriptores utilizados son las transformadas WAVELETH, FFT Y SFTF y e descriptor SFTA. En esta sección se describirá el proceso de extracción, como los métodos y modelos computacionales aplicados a cada descriptor.

### 3.3. Descriptor FFT

Para computar de este descriptor, inicialmente se realiza el cálculo de la transformada rápida de Fourier. Esto permite obtener un vector de características X1, el cual representa el espectro en frecuencia de la imagen analizada. Después de calcular X1, se procede a determinar los parámetros estadísticos utilizando las ecuaciones de la tabla 1. Donde xi es cada una de las muestras obtenidas en el cálculo de X1.

Parámetro	Ecuación
<b>Media</b>	$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{x_1 + x_2 + \dots + x_n}{n} \quad (12)$
<b>Desviación Estándar</b>	$s = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (13)$
<b>Sesgo</b>	$s_1 = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\left( \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \right)^3} \quad (14)$
<b>Kurtosis</b>	$k_1 = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\left( \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \right)^2} \quad (15)$

Tabla 1. Tabla de descriptores para realizar los cálculos anteriores se obtiene el vector de características FFT con dimensiones 4X1.

### 3.4. Descriptor STFT

Para realizar el cálculo de este descriptor, se computa la transformada corta en tiempo de Fourier. Este procedimiento genera un vector de características X2 que permite representar las variaciones de frecuencia con respecto al espacio de la imagen. Después de calcular X2, se procede a determinar los parámetros estadísticos de la tabla 1. Al realizar estos cálculos se obtiene el vector de características STFT con dimensiones 4X1.

### 3.5. Descriptor Wavelet

Para calcular este descriptor, se aplica la transformada Wavelet y se repite el procedimiento de los descriptores anteriores calculando los parámetros estadísticos de la tabla 1. Al realizar estos cálculos se obtiene el vector de características Wav con dimensiones 4X1.

### 3.6. Descriptor STFA

Para realizar el cálculo de este descriptor, inicialmente se debe aplicar los métodos TTBD que devuelve un conjunto de imágenes binarias para ser analizadas, posteriormente el vector de característica SFTA se calcula de las imágenes binarias resultantes, el nivel de gris medio y la dimensión fractal de los límites. Las mediciones fractales se emplean para describir la complejidad límite de objetos y estructuras segmentadas en la imagen de entrada. Los límites de las regiones de una imagen binaria  $I_b(x, y)$  se representan como una imagen gradiente  $\Delta(x, y)$ , calcula como:

$$\Delta(x, y) = \begin{cases} 1 & \text{si } \exists(x', y') \in N_8 [(X, Y)] : \\ & I_b(x', y') = 0 \wedge \\ & I_b(x', y') = 1 \\ 0, & \text{en otro caso} \end{cases} \quad (16)$$

Donde  $N_8 [(x, y)]$  es el conjunto de píxeles 8 vecinos.  $\Delta(x, y)$  toma el valor 1 si el pixel en la posición  $(x, y)$  en la imagen binaria correspondiente  $I_b(x, y)$  tiene el valor 1 y tiene al menos un pixel vecino con valor 0.

De otra manera toma el valor 0. La dimensión fractal  $D$  se calcula en la siguiente. El cálculo de la dimensión fractal se pueden utilizar para estimar y cuantificar la complejidad de la forma o textura de los objetos [13], [14]. La geometría fractal implica varios enfoques para definir las dimensiones fraccionarias, donde la más común es la dimensión de Hausdorff. Considerando un objeto que posee una dimensión euclidiana  $E$ , la dimensión fractal de  $D$  de Hausdorff se puede calcular por la siguiente expresión:

$$D_0 = \lim_{\epsilon \rightarrow 0} \frac{\log N(\epsilon)}{\log \epsilon^{-1}} \quad (17)$$

Donde  $N(\epsilon)$  es el recuento de hipercubos de dimensión E y longitud que llenan el objeto. Si consideramos un objeto representado por una imagen binaria  $I_b$ , se puede obtener una aproximación D para  $D_0$  mediante el algoritmo de recuento de cajas [15].

### 3.7. Entrenamiento y validación del modelo de clasificación

Esta etapa tiene como objetivo estimar el modelo de separación del modelo de aprendizaje y la validación de dicho modelo. Esta sección se divide en dos etapas. La primera etapa es el entrenamiento que tiene como objetivo la estimación de los parámetros intrínsecos del modelo y la segunda etapa que consiste en la validación de dicho modelo con metodología de validación cruzada con MonteCarlo para encontrar la convergencia del desempeño del clasificador garantizando relevancia estadística en la prueba. Para la etapa de clasificación, se utilizan dos enfoques de aprendizaje la SVM y las RNA, esto con el objetivo de verificar la pertinencia de estos descriptores bajo distintos métodos de aprendizaje.

Para las SVM, se utilizó con la estrategia de clasificación “*One-vs-All*”; este método de aprendizaje utiliza un kernel Gaussiano con radio adaptativo para la separación de los datos y la estimación de los vectores de soporte son calculados con el método de minimización *Sequential Minimal Optimization* (SMO), para lograr la implementación de este algoritmo se utilizó el *Statistics and machine learning toolbox* de Matlab® con la función *Fitcecoc*.

Es importante resaltar que necesario realizar una normalización gaussiana de los datos de entrenamiento como se plantea en la ecuación 18. Para la Red Neuronal se utilizó el algoritmo de *Backpropagation* con una capa oculta y veinte neuronas, esta selección se realizó de manera heurística y el criterio de elección de los parámetros escogidos es bajo el modelo con mejor desempeño en pruebas de validación.

$$z = \frac{x-\mu}{\sigma} \quad (18)$$

Se puede observar que  $\mu$  es el vector de medias de cada columna de la matriz de entrenamiento y  $\sigma$  es vector de desviaciones estándar de cada columna de esta matriz.

Para realizar el procedimiento de evaluación del modelo se utilizó una estrategia de validación cruzada, fraccionando de forma aleatoria con distribución uniforme la base de datos. El 70% de la base se utiliza para el entrenamiento y 30% restante para la validación en cada iteración; este proceso realiza estos cálculos de forma adaptativa garantizando la convergencia del experimento. El criterio de parada del experimento es  $\|diag(M_k) - diag(M_{k-1})\| < 0.002$ , donde  $diag(M_k)$  es el vector de la diagonal de la matriz de confusión y  $k$  es la iteración actual de Montecarlo.

Las estadísticas obtenidas en el experimento consisten en el cálculo de la matriz de confusión y el comportamiento promedio del porcentaje de acierto y su desviación estándar. Es importante resaltar que para evaluar un nuevo dato con el modelo entrenado, es necesario normalizar los datos bajo los parámetros de normalización del modelo utilizando la ecuación 18.

## 4. RESULTADOS

- La inspección visual en la industria textil es una actividad rigurosa que permite conocer el estado de los productos y verificar la calidad de los mismos. En este trabajo se escogen telas de interés comercial buscando obtener patrones que puedan ser diferenciados por variaciones en el hilado del textil, esto permite realizar un estudio sobre la capacidad de descripción que tiene las transformadas espacio-frecuencia y otros descriptores para reconocer diferentes tipos de telas. Este tipo de desarrollos ayudan a la implementación de sistemas expertos que permitan realizar procesos de inspección usando cámaras digitales como elemento sensor.
- En esta etapa se realizará el proceso de entrenamiento y validación a la base de datos anotada construida para este trabajo, esto con el objetivo de estudiar el desempeño de cada metodología de extracción de características propuesta para métodos clásicos de aprendizaje supervisado. Inicialmente se realizará el experimento de MonteCarlo para cada una de las pruebas y por último se realizará un análisis comparativo del desempeño de cada descriptor.

La tabla 2 muestra la matriz de confusión obtenida al realizar 15 iteraciones de MonteCarlo producto del experimento de validación cruzada. Este experimento se realizó para estudiar el desempeño que presenta la caracterización con el descriptor FFT y la clasificación con SVM. De esta tabla se observa un alto rendimiento para la detección de las diferentes telas, presentando porcentajes de acierto mayores al 95% para todas sus clases. La codificación de cada clase corresponde al número descrito en la sección de la base de datos anotada, un ejemplo de esto es c1 será equivalente a la tela de lana.

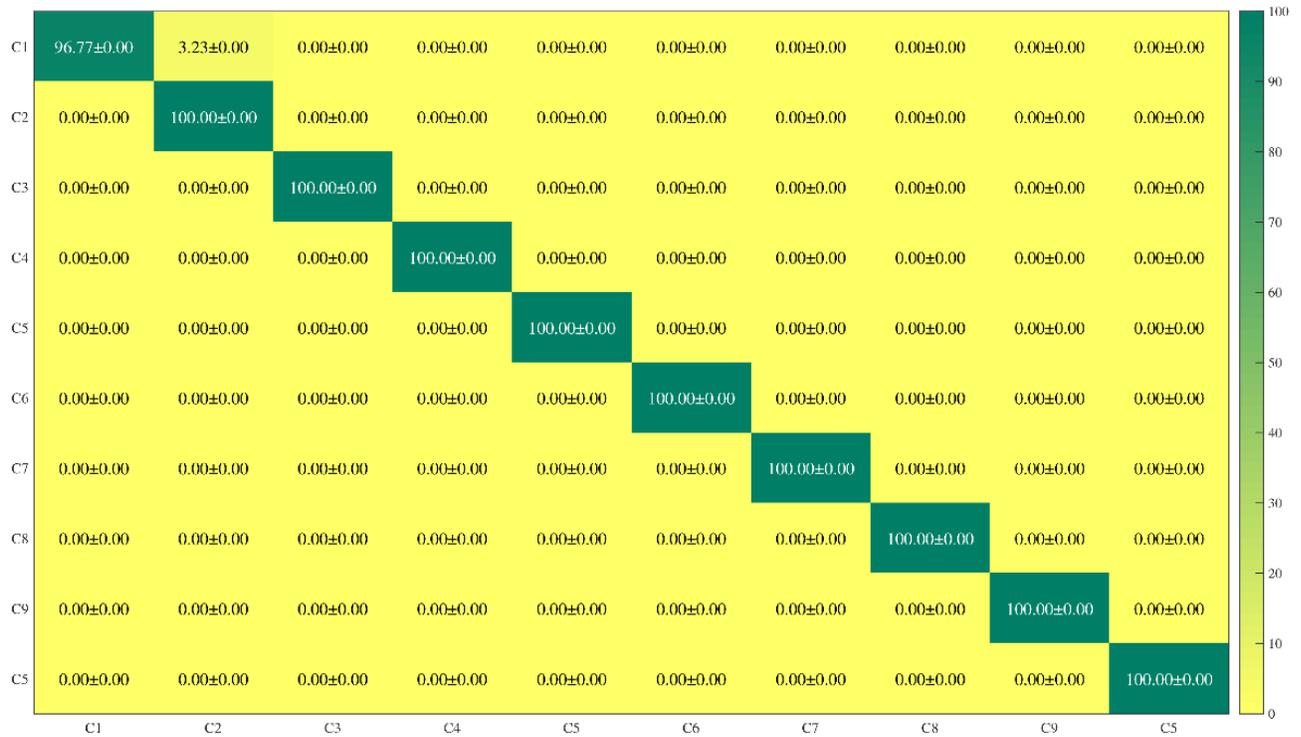


Tabla 2. Matriz de confusión método FFT-SVM

En la tabla 3 se puede observar la matriz de confusión para un total de 10 iteraciones de MonteCarlo. En este experimento se aplicó el método de caracterización con el descriptor STFT y método de clasificación SVM. De esta tabla se observa un alto rendimiento para la detección de las diferentes telas, presentando porcentajes de acierto perfectos del 100% para todas sus clases. Aunque durante el experimento el método de aprendizaje logró etiquetar correctamente los diferentes conjuntos de pruebas, fue la metodología con mayor costo computacional utilizando enfoque SVM. Los tiempos de entrenamiento en el experimento de MonteCarlo fueron significativamente alto con respecto a las demás metodologías logrando tiempo de 3 minutos por iteración.

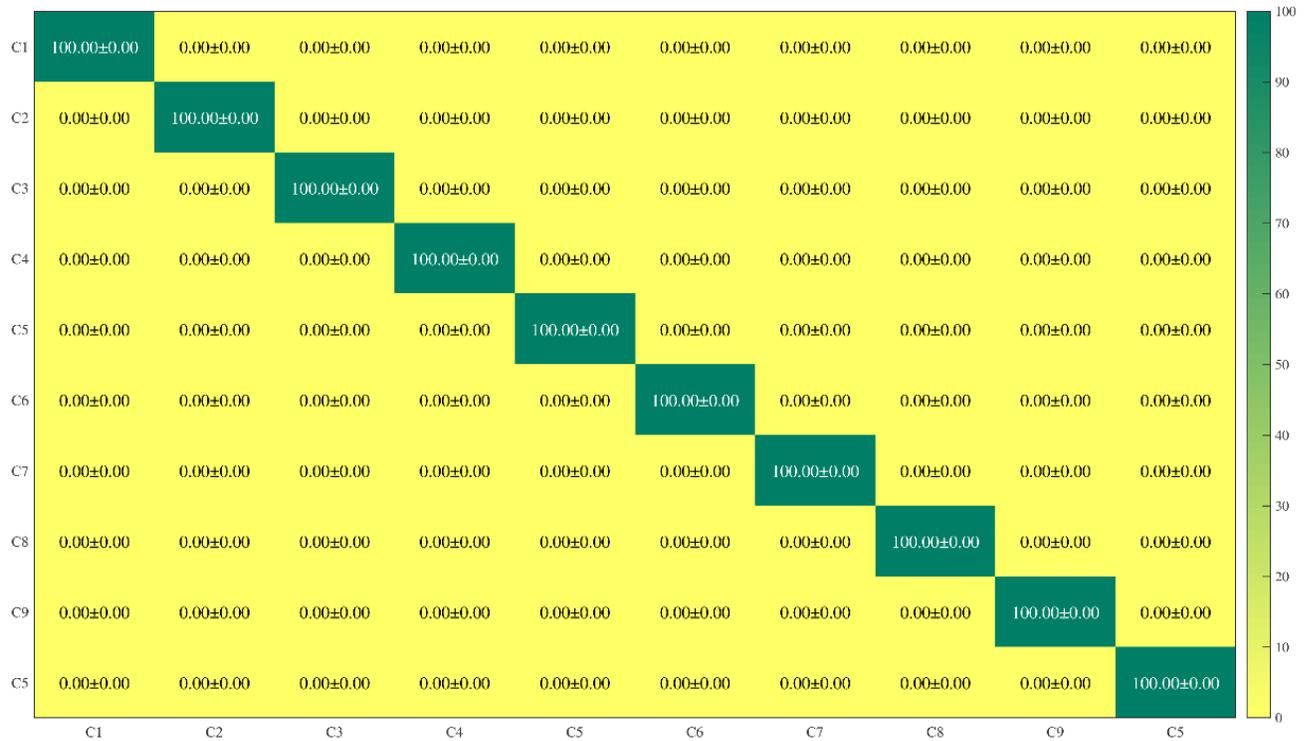


Tabla 3. Matriz de confusión método STFT-SVM

La tabla 4 muestra el desempeño de clasificación utilizando el método de caracterización Wavelet y clasificación con SVM. De esta tabla se observa un alto rendimiento para la detección de las diferentes telas, presentando porcentajes de acierto mayores al 90%. Sin embargo se puede observar en el experimento que las clases 4 y 8 presentan rendimientos en la escala del 70% porcentajes de acierto que evidencia una baja confiabilidad para detectar este tipo de variaciones.

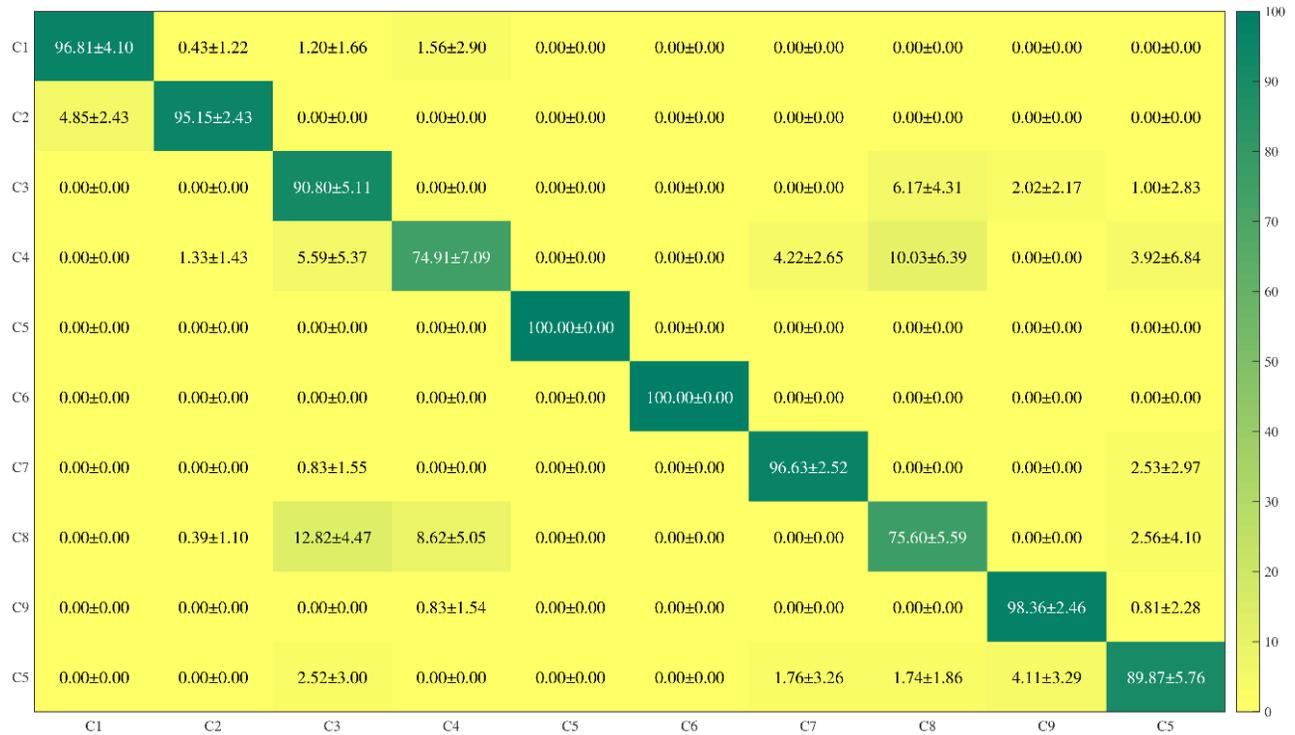


Tabla 4. Matriz de confusión método Wavelet-SVM

En la tabla 5 se puede observar el desempeño en la detección de la base de datos utilizando el método de caracterización STFA y clasificación con SVM. De esta tabla se observa un bajo rendimiento para la detección de las diferentes telas, presentando porcentajes de acierto menores al 90%, además de requerir un alto costo computacional. Esto hace pensar que esta metodología no es adecuada para detección fiable de este tipo de patrones

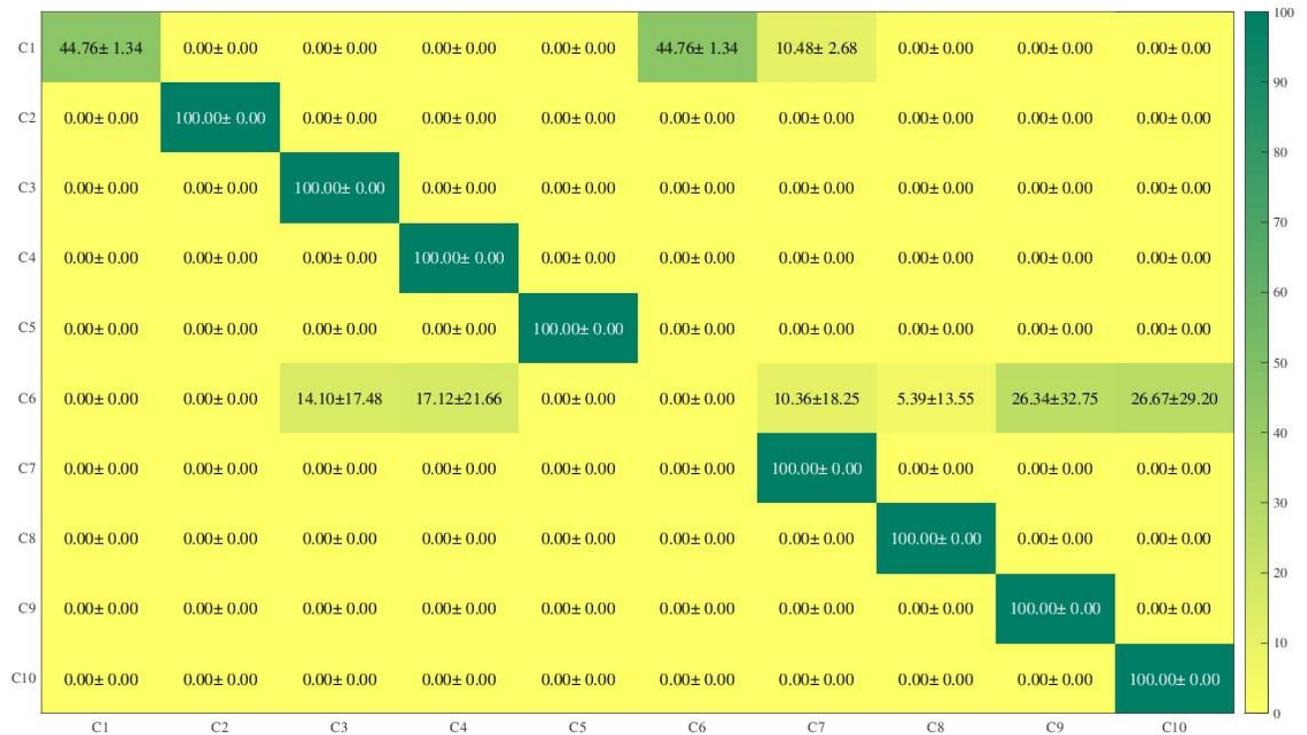


Tabla 5. Matriz de confusión método SFTA-SVM

Después de realizar experimentos de clasificación con SVM, se implementaron pruebas con otro método clásico de aprendizaje supervisado como las RNA. En la tabla 6 se observa el desempeño de clasificación de 33 iteraciones de MonteCarlo. Este experimento utiliza el método de caracterización FFT y clasificación con RNA. De esta tabla se observa un alto desempeño para la prueba presentando porcentajes de acierto mayores al 95%. Aunque en el experimento se observa un desempeño confiable, la desviación estándar tiende a ser mayor por clase, esto hace pensar que este método FFT-RNA tiene menor repetitividad que la metodología SVM-FFT. La clase 8 evidencia una alta variación, con un desempeño del  $97.25 \pm 8.03\%$ .

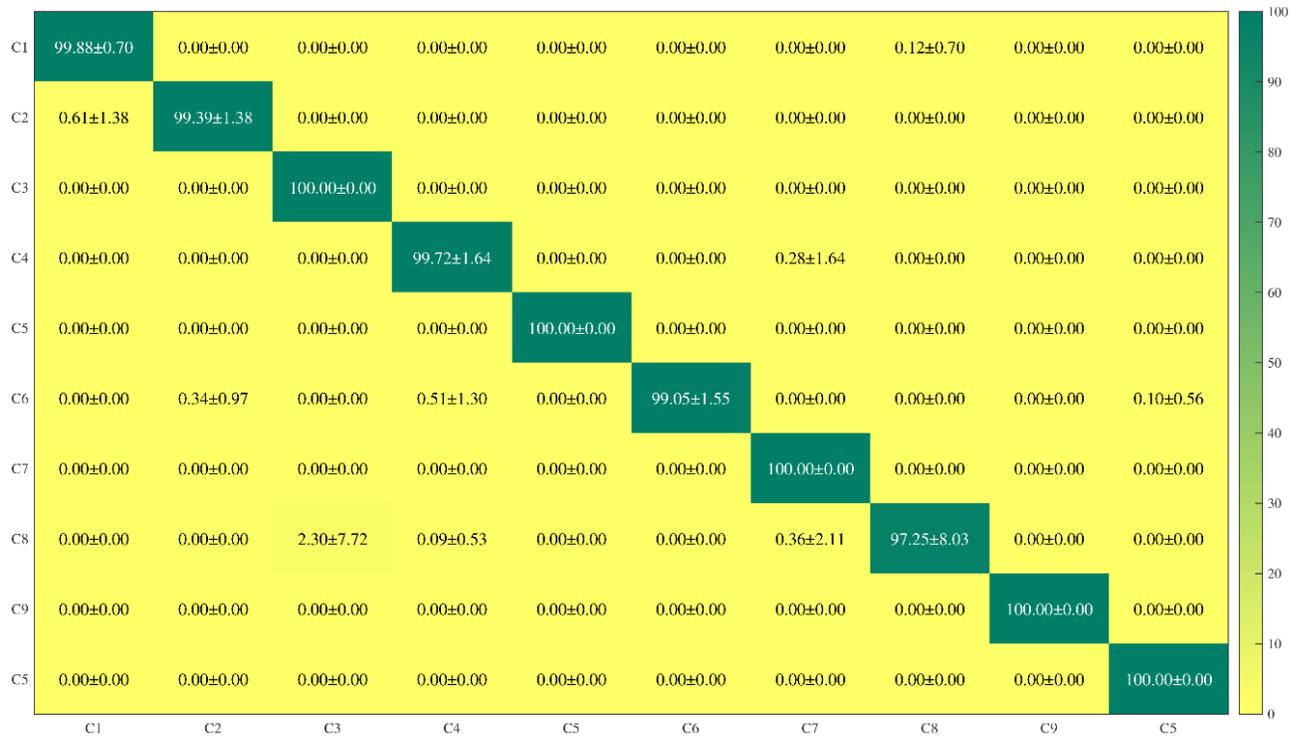


Tabla 6. Matriz de confusión método FFT-RNA

En la tabla 7 se puede observar la matriz de confusión para un total de 10 iteraciones de MonteCarlo. En este experimento se aplicó el método de caracterización con el descriptor STFT y el método de clasificación RNA. De esta tabla se observa un alto rendimiento para la detección de las diferentes telas, presentando porcentajes de acierto perfectos 100%. Estos resultados evidencian que este método caracterización presenta el mejor desempeño para describir las variaciones de textura de la base de datos. Sin embargo el costo computacional es significativamente, se hicieron cálculos de 11 minutos por iteración de MonteCarlo.

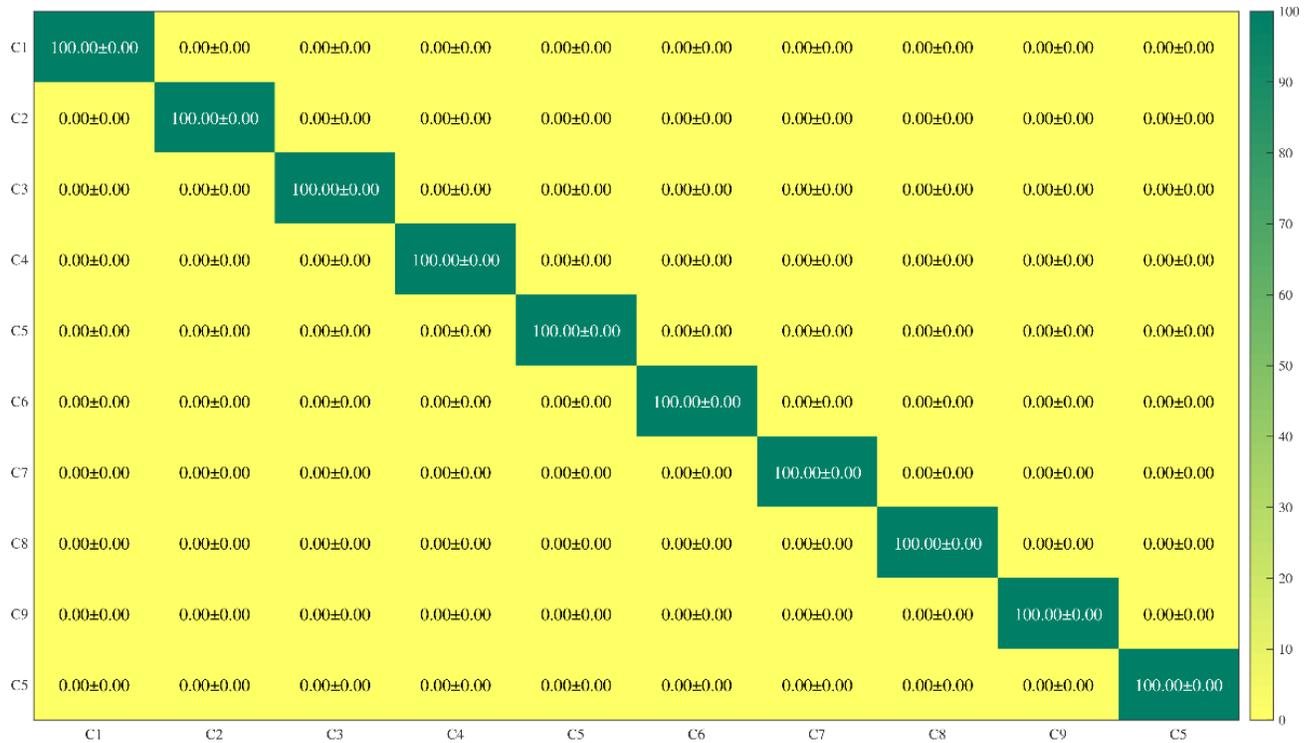


Tabla 7. Matriz de confusión método STFT-RNA

La tabla 8 muestra el desempeño de clasificación utilizando el método de caracterización Wavelet y clasificación con RNA. De esta tabla se observa un alto rendimiento para la detección de las diferentes telas, presentando porcentajes de acierto mayores al 90%. Sin embargo se observan rendimientos cercanos al 70%, repitiendo el comportamiento del método de clasificación Wavelet-SVM, esto implica que esta metodología de caracterización presenta baja confiabilidad para detectar las clases 4 y 8. Las clase 10 varía en un rango cercano al 90%, esto implica que su comportamiento es aceptable y se recomienda otro método de caracterización como FFT.

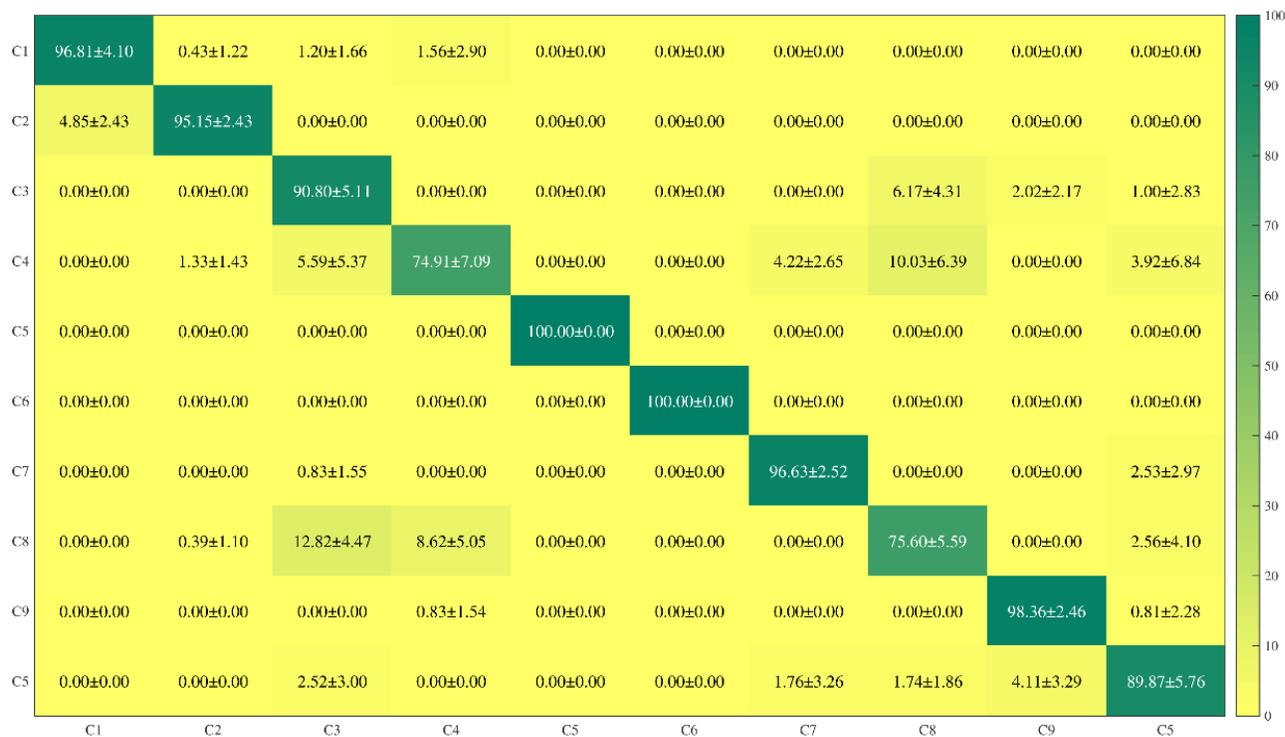


Tabla 8. Matriz de confusión método Wavelet-RNA

En la tabla 9 se puede observar el desempeño en la detección de la base de datos utilizando el método de caracterización STFA y clasificación con RNA. De esta tabla se observa un alto rendimiento para la detección de las diferentes telas, presentando porcentajes de acierto mayores al 96%. Esto demuestra que aunque esta metodología no demostró resultados satisfactorios con SVM, para este tipo de clasificador se logran obtener resultados importantes. A pesar de los buenos resultados se evidencia que el costo computacional para metodología es alto y lo hace inviable para sistemas con bajas prestaciones.

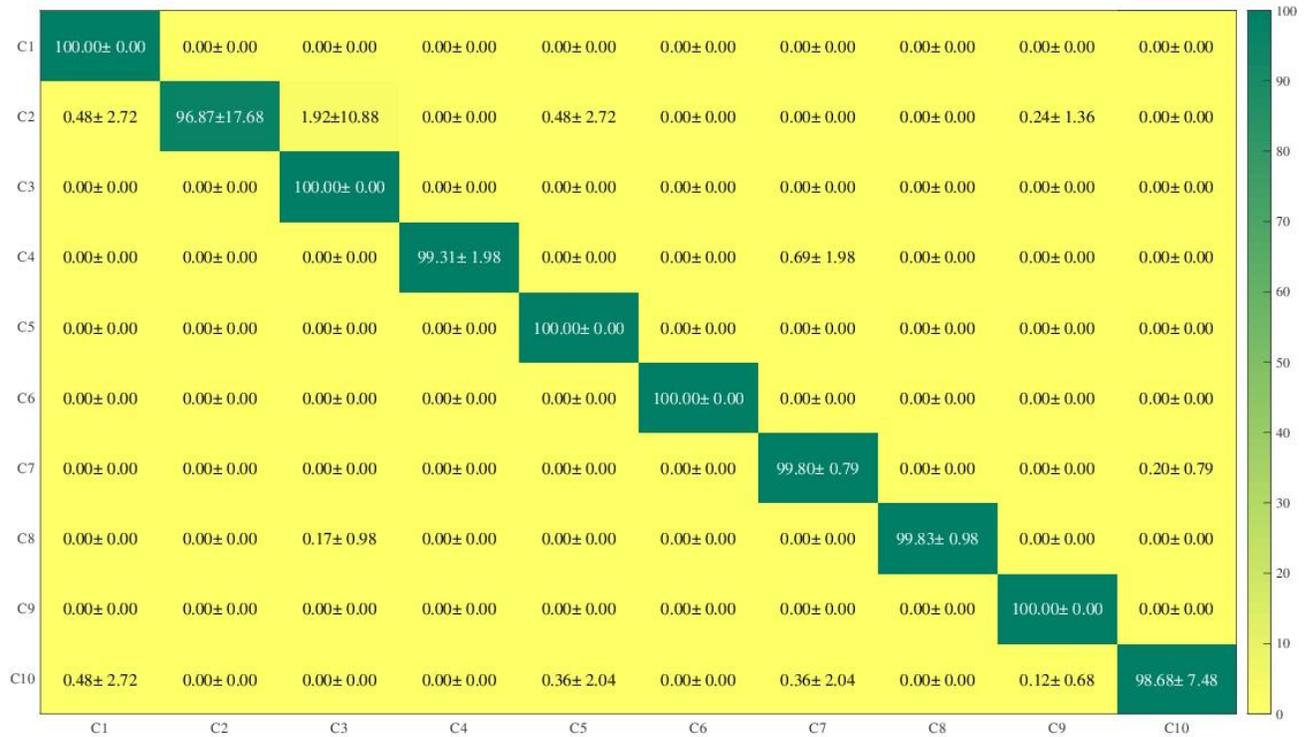


Tabla 9. Matriz de confusión método STFA-RNA

Con el objetivo de realizar un análisis comparativo entre las diferentes metodologías propuestas, se procede a calcular el desempeño de acierto promedio, este cálculo consiste en calcular el valor medio del vector resultante de la diagonal de la matriz de confusión. En la tabla 10 se puede observar el desempeño promedio para cada una de las metodologías propuestas en este trabajo.

SVM-FFT	RNA-FFT	SVM-STFT	RNA-STFT	SVM-Wavelet	RNA-Wavelet	SVM-STFA	RNA-STFA
99.67±1.02	99.52±0.86	100±0	100±0	91.81±9.36	91.81±9.36	84.48±34.39	99.45±1.01

Tabla 10. Desempeño promedio de metodologías para identificación de telas utilizando descriptores de textura

De la tabla 10 se puede observar que los métodos con mayor desempeño son los que utilizan el descriptor STFT, logrando un desempeño ideal del 100% para la base de datos propuesta, aunque estos desempeño son ideales, se evidencia los métodos de caracterización que utilizan la FFT presenta desempeños similares del 99% y su costo computacional es significativamente menor los que los hace ideales para una implementación en un sistema embebido. También se evidencia que la transformada Wavelet tiene un desempeño mayor al 90%, sin embargo su variabilidad es alta lo que sugiere un rango no aceptable para considerar este descriptor confiable para caracterizar variaciones de textura.

## 5. CONCLUSIONES

Se diseñó una metodología que permite utilizar la textura de las telas como descriptor, por medio de transformadas espacio frecuencia tales como FFT, STFT, Wavelet y STFA, aplicando metodologías de aprendizaje supervisado como SVM y RNA. Por medio de estas metodologías se alcanza conseguir resultados confiables mayores al 90% de eficiencia para una base de datos anotada de 10 telas diferentes. Se exceptúa de este resultado el método SFTA-SVM que no alcanzó obtener resultados mayores al 90% con una eficiencia de  $84.48 \pm 34.39$  para esta aplicación. Sin embargo se resalta que al cambiar el clasificador por una RNA el método SFTA presenta una eficiencia del  $99.45 \pm 1.01$ , pero requiere de un alto costo computacional para la extracción de características como para la clasificación.

Aunque los métodos de STFT- SVM y STFT-RNA lograron un desempeño del 100% demostrando ser una metodología más que adecuada para este tipo de aplicaciones, no es recomendable utilizarlos ya que este desfragmenta la imagen y aplica la FFT en diferentes segmentos generando un alto costo computacional para una implementación en un sistema embebido. En la transformada Wavelet con SVM y RNA, el desempeño es mayor al 90%, sin embargo el error es alto por lo que sugiere un rango que no es aceptable para considerar este descriptor en una aplicación. Por último, el resultado que se obtuvo con el método de la FFT con SVM y RNA, presentaron un desempeño del 99% con un mínimo error y un costo computacional es significativamente menor con respecto a los demás descriptores, por lo tanto se puede considerar que este es el mejor descriptor para ser implementado en un sistema embebido, debido a que estadísticamente presenta un funcionamiento similar al del mejor rendimiento (STFT), con un costo de cómputo razonable.

## 6. REFERENCIAS

- [1] Control de calidad textil. [En línea]. Disponible en: <http://www.detextiles.com/files/CONTROL%20DE%20CALIDAD%20TEXTIL.pdf>
- [2] C. Spinola et al., "Image processing for surface quality control in stainless steel production lines," 2010 IEEE International Conference on Imaging Systems and Techniques, Thessaloniki, 2010, pp. 192-197.
- [3] M. Sharifzadeh, S. Alirezaee, R. Amirfattahi and S. Sadri, "Detection of steel defect using the image processing algorithms," 2008 IEEE International Multitopic Conference, Karachi, 2008, pp. 125-127.
- [4] P. L. Mazzeo, L. Giove, G. M. Moramarco, P. Spagnolo and M. Leo, "HSV and RGB color histograms comparing for objects tracking among non overlapping FOVs, using CBTF," 2011 8th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS), Klagenfurt, 2011, pp. 498-503.
- [5] Arias, N., & Ortiz, A. (2016). ANÁLISIS COMPARATIVO DE DESCRIPTORES PARA LA CLASIFICACIÓN DE TELAS UTILIZANDO IMÁGENES. Universidad Tecnológica de Pereira, Pereira, Colombia.
- [6] A. Luna, M. Angel, "Análisis del Clúster Textil en el Perú". [En línea]. Disponible en: [http://sisbib.unmsm.edu.pe/bibvirtualdata/Tesis/Ingenie/angulo\\_lm/cap2.PDF](http://sisbib.unmsm.edu.pe/bibvirtualdata/Tesis/Ingenie/angulo_lm/cap2.PDF)
- [7] COATS, "Todo Sobre Fibras Textiles". [En línea]. Disponible en: [http://www.coatsindustrial.com/es/images/Know\\_About\\_Textile\\_Fibres\\_tcm62-9073.pdf](http://www.coatsindustrial.com/es/images/Know_About_Textile_Fibres_tcm62-9073.pdf)
- [8] Hernando Ríos, L. (2015) SISTEMA DE CLASIFICACIÓN Y RECONOCIMIENTO DE IMÁGENES". Universidad Tecnológica de Pereira, Pereira, Colombia.

[9] H.O. Gómez Espinoza,” Aplicación de la Transformada Wavelet y el Método Level Set para el filtrado y segmentación de imágenes”, Trabajo de grado para Título de Ingeniero Electrónico, facultad de ingenieras, Universidad Politécnica Salesiana, Cuenca, Ecuador, 2012.

[10] UDLAP, “Capitulo 3. Revisión de la teoría de Wavelets”. [En línea]. Disponible en: [http://catarina.udlap.mx/u\\_dl\\_a/tales/documentos/mel/gonzalez\\_g\\_ra/capitulo3.pdf](http://catarina.udlap.mx/u_dl_a/tales/documentos/mel/gonzalez_g_ra/capitulo3.pdf)