

ANÁLISIS COMPARATIVO DE DESCRIPTORES PARA LA  
CLASIFICACIÓN DE TELAS UTILIZANDO IMÁGENES

NELSON ENRIQUE ARIAS GAVIRIA  
JORGE ANDRÉS ORTIZ RUÍZ

UNIVERSIDAD TECNOLÓGICA DE PEREIRA  
FACULTAD DE INGENIERÍAS, RISARALDA  
INGENIERÍA ELECTRÓNICA  
PEREIRA  
2016

ANÁLISIS COMPARATIVO DE DESCRIPTORES PARA LA  
CLASIFICACIÓN DE TELAS UTILIZANDO IMÁGENES

NELSON ENRIQUE ARIAS GAVIRIA

JORGE ANDRÉS ORTIZ RUÍZ

PROYECTO DE GRADO

ARLEY BEJARANO MARTÍNEZ, MSc(C).

UNIVERSIDAD TECNOLÓGICA DE PEREIRA

FACULTAD DE INGENIERÍAS, RISARALDA

INGENIERÍA ELECTRÓNICA

PEREIRA

2016

**Nota de aceptación:**

---

---

---

---

---

---

---

---

**Firma Director de Trabajo de Grado**  
**MSc(C). ARLEY BEJARANO MARTÍNEZ**

---

**Firma del Jurado**

---

**Firma del Director de Programa**  
**Msc. EDWIN ANDRÉS QUINTERO**

**Pereira, junio de 2016**

## DEDICATORIA

*Inicialmente quisiera dedicar este trabajo a Dios ya que me ha permitido llegar hasta esta instancia de mi carrera y me ha dado lo necesario para lograrlo; de igual forma quiero agradecer a mis padres que me han enseñado valores para un buen ejemplo en la sociedad. También quiero dedicarlo a todas aquellas personas que de una u otra manera han aportado un poco, permitiéndome crecer de forma positiva en muchos sentidos.*

**NELSON ENRIQUE ARIAS GAVIRIA**

*Inicialmente deseo dedicarle este trabajo con mucha fe a Dios, por haberme brindado el acompañamiento y la salud durante el desarrollo de mi carrera universitaria.*

*También y con el amor más grande a mi madre que siempre quiso verme como un profesional y que siempre creyó en mí y a la ayuda incondicional que me brindo mi familia y a dos seres muy especiales que me llenaron de valor, fe, esperanza este sueño hecho realidad y también al apoyo de todas las personas que me acompañaron e hicieron posible este proceso de mi vida*

**JORGE ANDRÉS ORTIZ RUÍZ**

## AGRADECIMIENTOS

*Agradecemos a nuestro Director Arley Bejarano Martinez por darnos la oportunidad de realizar éste trabajo y por sus aportes durante el desarrollo de éste. También queremos agradecer a Wilinton Farid Cardona por sus asesorías y el conocimiento brindado el cual nos sirvió como guía para la finalización de éste trabajo.*

# TABLA DE CONTENIDO

	Pág.
<b>1. INTRODUCCIÓN</b>	<b>10</b>
<b>2. OBJETIVOS</b>	<b>11</b>
2.1. Objetivo general . . . . .	11
2.2. Objetivos específicos . . . . .	11
<b>3. METODOLOGÍA</b>	<b>12</b>
3.1. Captura de la base de datos. . . . .	12
3.2. Extracción de características. . . . .	12
3.2.1. Transformada rápida de Fourier (FFT) . . . . .	12
3.2.2. Transformada wavelet . . . . .	14
3.2.3. Transformada de Fourier corta en espacio (SSFT) . . . . .	14
3.3. Algoritmos de aprendizaje de maquina. . . . .	15
3.3.1. Máquina de vectores de soporte(SVM) . . . . .	15
3.3.2. Redes de neuronas artificiales(RNA) . . . . .	16
3.4. Análisis estadístico. . . . .	16
<b>4. RESULTADOS</b>	<b>17</b>
4.1. Entrenamiento de SVM utilizando los descriptores obtenidos por las transformadas FFT, wavelet, SSFT. . . . .	18
4.1.1. Máquinas de vectores de soporte utilizando la transformada de Fourier. . . . .	18
4.1.2. Maquinas de vectores de soporte utilizando la transformada de Wavelet . . . . .	22
4.1.3. Maquinas de vectores de soporte utilizando la transformada de Fourier corta en espacio (SSFT) . . . . .	26
4.2. Comparación de las transformadas por SVM . . . . .	30
4.3. Entrenamiento de RNA utilizando los descriptores obtenidos por las transformadas FFT, Wavelet, SSFT. . . . .	31
4.3.1. RNA con la Transformada de Fourier . . . . .	31
4.3.2. RNA con Transformada de Wavelet . . . . .	32
4.3.3. RNA con Transformada de Fourier corta en espacio (SSFT) . . . . .	34
4.4. Comparación de las transformadas por RNA . . . . .	35
4.5. Comparación entre SVM y RNA . . . . .	35
<b>5. CONCLUSIONES, APORTES Y RECOMENDACIONES</b>	<b>37</b>

## Índice de cuadros

1.	Características de la cámara . . . . .	17
2.	Resultados de los descriptores en máquinas de soporte vectorial . . . . .	31
3.	Datos de los descriptores que estimen el error en RNA . . . . .	35
4.	Cuadro comparativo . . . . .	36

## LISTA DE FIGURAS

1.	Transformada de Fourier de la imagen . . . . .	13
2.	Transformada de Wavelet, imagenes de horizontal, vertical, diagonal. . . . .	14
3.	SSFT imagen descompuesta por ventanas . . . . .	15
4.	Fotografía del sistema de toma de imágenes . . . . .	17
5.	Tipos de imágenes de telas implementados . . . . .	18
6.	SVM diagramas de dispersión FFT . . . . .	19
7.	Separación lineal SVM, matriz de confusión FFT . . . . .	20
8.	Separación cuadrática SVM, matriz de confusión FFT . . . . .	21
9.	Separación cubica SVM, matriz de confusión FFT . . . . .	22
10.	SVM diagramas de dispersión Wavelet . . . . .	23
11.	Separación lineal SVM matriz de confusión Wavelet . . . . .	24
12.	Separación cuadrática SVM matriz de confusión Wavelet . . . . .	25
13.	Separación cubica SVM matriz de confusión Wavelet . . . . .	26
14.	SVM Diagrama de dispersión para SSFT . . . . .	27
15.	Separación lineal SVM matriz de confusión SSFT . . . . .	28
16.	Separación cuadrática SVM matriz de confusión SSFT . . . . .	29
17.	Separación cubica SVM matriz de confusión SSFT . . . . .	30
18.	RNA para los descriptores de la FFT. . . . .	31
19.	Matriz de confusión RNA para FFT . . . . .	32
20.	RNA para los descriptores de la wavelet . . . . .	33
21.	Matriz de confusión RNA Para las Waveles . . . . .	33
22.	RNA para la para los descriptores de la SSFT . . . . .	34
23.	Matriz de confusión RNA para SSFT . . . . .	34
24.	Matriz de conjunción de los diferentes métodos en RNA . . . . .	35



## Resumen

En este documento se realiza un estudio comparativo entre diferentes métodos de aprendizaje y descriptores. Para esto se realizó una base de datos con quinientas imágenes de telas, de cinco clases diferentes que fueron tomadas por medio de un celular Samsung Galaxy Ace S5830, de gama media, el cual cuenta con una cámara de cinco megapixels, con una resolución de dimensión de 2560 píxeles de ancho por 1920 píxeles de alto. Las telas seleccionadas fueron: lino, blonda, escuba, velo, acetato. Para obtener las características se plantea tres descriptores utilizando transformadas tiempo frecuencia (transformada rápida de Fourier (FFT), transformada de Wavelet, Transformada de Fourier corta en espacio (SSFT)). Se seleccionaron estas transformadas para las imágenes textiles, ya que al ser capturados por medio de una cámara las señales que aparecen son periódicas, a estas transformadas se les calcula los parámetros estadísticos con medidas descriptivas de centralización (media, moda, curtosis y desviación estándar). Estos descriptores se utilizan como característica para entrenar dos métodos de aprendizaje máquina supervisado, redes neuronales (RNA) y máquinas de soporte vectorial (SVM), los cuales tienen la característica de predecir y clasificar las telas con un margen de error pequeño a partir de los datos.

Combinando los dos métodos de aprendizaje máquina y los clasificadores se busca hacer un análisis comparativo el cual determine que método presenta mejor desempeño a nivel de clasificación.

## 1. INTRODUCCIÓN

La industria textil es el sector económico influyente en el territorio nacional que se encuentra principalmente entre las redes empresariales de Antioquia y Bogotá, pero a nivel general se encuentra ubicadas principalmente: Medellín, Cali, Pereira, Manizales, Barranquilla, Ibagué y Bucaramanga, en el Valle de Aburra se encuentran las tradicionales y antiguas empresas textiles del país, Coltejer, Fabricato y Tejicondor, que trabajan a partir de algodón y sus mezclas [1].

Debido al incremento de la producción nacional e internacional se ha vuelto necesaria la creación de nuevas fibras, como también el incremento de personal capacitado para poder cumplir con dichas demandas y la creación de nuevas herramientas tecnológicas que facilitan la producción en masa.

Los sistemas automáticos y de control requieren un proceso de programación adaptados a las necesidades de la industria para la producción, esta labor cumple un papel importante, en la medida que busca reducir costos y lograr altos niveles de productividad. Es necesario por tanto, que las empresas innoven no sólo en sus procesos productivos, sino también en sus herramientas de gestión y de desarrollo. Para poder cumplir con la demanda de la industria hoy en día las empresas del sector textil, aparecen como principales protagonistas dentro del estudio de sectores de clase mundial.

En Colombia existen investigaciones patrocinadas por el ministerio de comercio, industria y turismo, de estas investigaciones es importante resaltar que las principales tendencias mundiales en el tema de textiles, están orientadas por las preocupaciones que tienen los consumidores por temas éticos como el cambio climático. La manufactura de textiles y el control de calidad de este producto (tela) en los procesos de producción como fuente de ingresos es de suma importancia y gran impacto económico. Determinar el tipo de tela es un proceso fundamental sobre todo cuando se habla de procesos a gran escala, ya que un operario no puede realizar esta labor, por la variedad y la cantidad del material en los procesos de manufactura. Por esta razón las fabricas cada día están más a la vanguardia con la tecnología, pero no se acaba del todo la intervención del hombre en los procesos de producción, el reconocimiento y clasificación de las telas es una labor que lleva tiempo y requiere conocimiento sobre el tema.

A través del tiempo se ha tratado de clasificar las telas con métodos que implementan técnicas de visión por computador, ya que gracias a la tecnología los sistemas electrónicos incrementan día a día sus capacidades de procesamiento, haciendo la labor de análisis e interpretación de imágenes de forma automática[2]. Aprovechando este recurso, donde el procedimiento de adquisición lo realiza eficazmente una máquina, para descubrir de manera automática, sin importar los diferentes tipos de material que está hecho la tela y poderla clasificar.

## **2. OBJETIVOS**

### **2.1. Objetivo general**

> Realizar un análisis comparativo de descriptores para la clasificación de telas utilizando imágenes.

### **2.2. Objetivos específicos**

- Crear una base de datos anotada de cinco diferentes tipos de telas.
- Implementar tres diferentes descriptores que permitan obtener la información relevante de la imagen.
- Implementar una máquina de soporte vectorial utilizando los descriptores obtenidos que permita clasificar los diferentes tipos de telas.
- Realizar un análisis estadístico de los diferentes descriptores.

### 3. METODOLOGÍA

Con el fin de cumplir con los objetivos, se planteó una metodología estructurada la cual consta de cuatro pasos, los cuales se mostraran a continuación:

#### 3.1. Captura de la base de datos.

Para la creación de la base de datos se tomaron 100 imágenes de cinco tipos de telas diferentes (lino, blonda, escuba, velo, acetato) para un total de 500 imágenes, que fueron capturadas por una cámara digital de un smartphone Samsung Galaxy Ace S5830 el cual cuenta con una cámara de 5 Mp , con una resolución de dimensión de 2560 pixeles de ancho por 1920 pixeles de alto. Para esta labor se acondiciona un monopodo 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. El dispositivo implementado para la captura de imágenes esta sobre una plataforma fija, la cual para este caso una mesa de prueba, con el espacio suficiente para poder extender las telas y mover las libremente para que cada imagen sea distinta, el ambiente donde se capturan las imágenes posee iluminación controlada, para lograr esto se colocan dos lámparas led.

#### 3.2. Extracción de características.

Para la extracción de características se utilizan diferentes transformadas tiempo frecuencia ya que se implementan descriptores como la representación paramétrica de la transformada de Fourier por ser métodos efectivos para la reconstrucción de imágenes textiles, ya que estas tienen imágenes cuasi-periódicas por estas características son objetivo de estudio, y se implementan en la clasificación, verificación y reconocimiento de formas geométricas en una imagen.

##### 3.2.1. Transformada rápida de Fourier (FFT)

Cuando una imagen contiene estructuras periódicas, como es el caso de las imágenes de tejidos textiles que presentan un alto grado de periodicidad, su transformada de Fourier (TF), tiene un aspecto característico representado con picos de intensidad correspondientes a las frecuencias espaciales de sus estructuras. De esta forma se propone el uso de descriptores geométricos para la TF digital, que están relacionados con los picos máximos de la transformada de Fourier (tomando como centro del espacio coordenado, el pico máximo) y están asociados a la estructura pseudoperiódica elemental del tejido, llevando a cabo la caracterización de diversos tejidos y poder realizar clasificación de muestras independientemente de variaciones de rotación, traslación y cambio de escala[5]. Se implementa primero la serie de Fourier de una función periódica se escribe así:

$$f(t) = \frac{1}{2}a_0 \sum_{k=1}^{\infty} (a_k \cos 2\Pi kt + b_k \sin 2\Pi kt) \quad (1)$$

Ecuación 1. Series de Fourier

La transformada de Fourier es el procedimiento matemático que descompone una función en las frecuencias que le forman de la misma manera que un prisma descompone

la luz en los diferentes colores y longitudes de onda[7]. Si se hace el período de la función a transformar tiende a infinito, se obtiene la transformada de Fourier de la función.

$$C(w) = \frac{1}{2} \int_{-\infty}^{\infty} f(t)e^{-iwt} dt \quad (2)$$

Ecuación 2. Transformada de Fourier

La transformada de Fourier digital de imágenes del tejido para caracterizar las etapas fundamentales del método son:

- Llevar la imagen a una escala de grises para evitar el brillo de la imagen y poder contrarrestar un factor como lo es el ruido a la hora de procesar al imagen y obtener mejores resultados.
- Ubicación de las posiciones de los picos más altos respecto al orden central, uno por cada una de las vecindades y etiquetarlos de forma ascendente.
- Cálculo de modelos estadísticos como, la media, la moda, desviación estándar curtosis, para poder sacar las características fundamentales de la imagen.
- Proceder con la clasificación y comparación con los estándares establecidos Previamente. Los descriptores geométricos están relacionados con los picos máximos de la transformada de Fourier.

A continuación se muestra la transformada de Fourier para una imagen textil a color, que en el proceso de transformada es pasada a escala de grises para poder describir mejor la imagen, y a la hora de sacar sus picos más altos tenga un mejor rendimiento ya que no se implementa color en las imágenes. Ver figura(1)




Figura 1: Transformada de Fourier de la imagen

El algoritmo es eficiente en cuanto al tiempo de cómputo para grandes arreglos de entrada cuya longitud es una potencia entera de dos, recibe el nombre de transformada de Fourier rápida, la transformada de Fourier descompone la señal en senos y cosenos de diferentes frecuencias y amplitudes.

$$X[k] = \sum_{n=0}^{N-1} X[n]e^{-i2\pi k \frac{n}{N}} \quad k = 0, \dots, N - 1. \quad (3)$$

Ecuación 3. Transformada discreta de Fourier

N = Número de Muestras.

n = Enésima muestra original.

k = Désimo término de la DTFs.

### 3.2.2. Transformada wavelet

La transformada de Wavelet es un descriptor fundamental a la hora de implementar la base de datos de las telas. La eficiencia de las Wavelets en representar señales e imágenes con discontinuidades es una clave para su utilidad con problemas como compresión de datos y eliminación de ruido, singularidades y bordes, que son difíciles de discernir desde una transformada de Fourier, aparecen claramente en la transformada de Wavelet. Por tanto, el análisis de Wavelet puede ayudar a identificar más rápidamente ocurrencias importantes localizadas en una imagen[3].

Para describir la imagen se implementó la transformada de Wavelet Haar conocida ahora como el primer Wavelet, que usando estas funciones para dar un ejemplo de un sistema ortonormal contable para el espacio de las funciones de cuadrado integrable en la recta real. Como se puede observar en la imagen la transformada de Wavelet hace tres mapeos de la imagen, vertical, horizontal, diagonal. Ver figura(2)




Figura 2: Transformada de Wavelet, imagenes de horizontal, vertical, diagonal.

De manera muy general, la transformada Wavelet de una función  $f(t)$  es la descomposición de  $f(t)$  en un conjunto de funciones  $\psi$ , que forman una base generadora la cual se llama Wavelets.

. La primera vez que se utilizó la expresión Wavelet fue en 1909 en un apéndice de la tesis de A Haar[9]. Los sistemas de Haar describen el conjunto de Wavelets de Haar.

$$\{t \mapsto \psi_{n,k}(t) = \psi(2^n t - k); n \in \mathbb{N}, 0 \leq k < 2^n\} \quad (4)$$

Ecuación 4. Sistema Wavelets de Haar

Los coeficientes de las Wavelets que quedan aún tras la cuantización corresponden a píxeles que son distintos a sus vecinos, en el borde de los objetos de una imagen. Por tanto, las Wavelets recrean una imagen principalmente trazando bordes, que es parecido a lo que hacen los humanos cuando esbozan un dibujo[10].

$$W_f(s, \tau) = \int f(t) \psi_{s,\tau}(t) dt. \quad (5)$$

Ecuación 5. Transformada de Wavelet.

### 3.2.3. Transformada de Fourier corta en espacio (SSFT)

Se implementa el descriptor de Fourier de tiempo corto en espacio (SSFT), la imagen se divide en ventanas. Esta definición puede generalizarse de una manera directa para incluir multidimensional funciones. Sin embargo, las señales dimensionales, se definen




Figura 3: SSFT imagen descompuesta por ventanas

solamente sobre una región finita[4]. Lo que se hace con esta transformada es tomar toda la imagen y dividirla en pequeñas imágenes, a estas regiones se les aplica la FFT, obteniendo así la SSFT, que también presenta un mapa de energía que se puede utilizar para diferenciar o distinguir regiones de la imagen textil. Ver figura(3)

Para una sola dimensión, duración infinita señal discreta,  $x(n)$ , el corto espacio de Fourier Transformada se ha definido como.

$$X(n, w) = \sum_{m=-\infty}^{\infty} x(m)w(n-m)e^{-jwm} \quad (6)$$

Esta definición puede generalizarse de una manera directa para incluir multidimensional funciones de extensión infinita. Sin embargo, las señales dimensionales, se definen solamente sobre una finita región, se definen la transformada de Fourier corta en espacio de la siguiente manera.

$$X(n, w) = \sum_{m_1=0}^{2N_1-1} \sum_{m_2=0}^{2N_2-2} \dots \sum_{m_L=0}^{2N_L-1} x^{\sim}(m)w^{\sim}(n-m)e^{-jM^T W} \quad (7)$$

Ecuación 7. Transformada de Fourier corta en espacio.

### 3.3. Algoritmos de aprendizaje de maquina.

A las transformadas anteriores se le calculo los momentos estadísticos con el fin de obtener los descriptores o características para realizar los dos métodos de aprendizaje maquina supervisado.

#### 3.3.1. Máquina de vectores de soporte(SVM)

Las máquinas de vectores de soporte están propiamente relacionadas con problemas de clasificación y regresión. Dado un conjunto de ejemplos de entrenamiento (de muestras) se puede etiquetar las clases y entrenar una SVM para construir un modelo que prediga la clase de una nueva muestra.

SVM construye un hiperplano o un conjunto de hiperplanos en un espacio de alta dimensionalidad, donde los vectores de soporte lo que hacen es encontrar un hiperplano que separe la mayor cantidad de datos posibles, en el caso en que los datos sean no lineales, porque desafortunadamente los datos a estudiar no se suelen presentar en casos

exactos, se implementa otra dimensión utilizando la función de kernel, Estas funciones son las que le permiten convertir lo que sería un problema de clasificación no-lineal en el espacio dimensional original, a un sencillo problema de clasificación lineal en un espacio dimensional mayor, que ofrece una solución a este problema, el cual aumenta la capacidad computacional de la máquinas de aprendizaje ya que una buena separación entre las clases permitirá un clasificación correcta[6].

Una SVM es un modelo que representa a los puntos de muestra en el espacio, separando las clases por un espacio lo más amplio posible. Cuando las nuevas muestras se ponen en correspondencia con dicho modelo, en función de su proximidad pueden ser clasificadas a una u otra clase.

### **3.3.2. Redes de neuronas artificiales(RNA)**

Como herramienta de clasificación de datos se implementa redes de neuronas artificiales (denominadas habitualmente como RNA) conocidas como inteligencia artificial que son mecanismos de aprendizaje y procesamiento automático, se trata de un sistema de interconexión de neuronas que colaboran entre sí para reproducir un estímulo de salida.

Las RNA desde hace décadas se ha convertido en la herramienta para resolver problemas en cualquiera de los niveles del procesamiento de imágenes. Esto debido a que las imágenes digitales contienen mucha información difícil de interpretar por una máquina. Utilizadas más que todo en las tareas de segmentación y clasificación las neuronas, funcionan como dispositivos booleanos que presentan una arquitectura en tres capas y un algoritmo de aprendizaje[8]el cual se utilizo como un detector de características que permiten la clasificación de las imágenes, donde cada neurona tiene asociada una función matemática denominada función de transferencia y dicha función genera la señal de salida de la neurona a partir de las señales de entrada.

### **3.4. Análisis estadístico.**

Combinando las diferentes transformadas con sus respectivos momentos estadísticos, se aplicaron los dos métodos maquina conocidos como maquinas de vectores de soporte(SVM) y redes neuronales(RNA) . Se realiza un análisis estadístico combinando los diferentes descriptores con los métodos de aprendizaje supervisado con el fin de determinar cual es el mejor método para clasificar los cinco tipos de telas. Para dicho análisis se utilizo diagramas de dispersión y matrices de confusión los cuales permiten observar los resultados de una manera clara y precisa.



#### 4. RESULTADOS

Para el desarrollo de este trabajo se utilizarán imágenes pertenecientes a la industria textil. Ver cuadro (1)

Características de la cámara	
Resolución cámara de fotos	5 Megapíxeles
Resolución cámara de fotos (alto)	1944 Píxeles
Resolución cámara de fotos (ancho)	2592 Píxeles
Tipo de flash	Led

Tabla 1: Características de la cámara

La base de datos se construye con 5 tipos de telas diferentes(lino, blonda, escuba, velo, acetato) se obtuvo 100 imágenes de cada una con un total de una base de datos de 500 fotos, para cada una se tiene en cuenta el factor de la luz, ruido, sombra, rotación; donde la imagen tiene una dimensión de 2560 píxeles de ancho por 1920 píxeles de alto en el proceso de captura, se presenta una fotografía del sistema propuesto para la captura de las imágenes. Con el acondicionamiento necesario de lámparas led se hace iluminación controlada. Ver figura(4)



Figura 4: Fotografía del sistema de toma de imágenes

A continuación se muestra los 5 tipos de telas implementados, con un total de 100 imágenes para cada clase, que forman una base de 500 telas. Ver figura(5)



Figura 5: Tipos de imágenes de telas implementados

Cada imagen está en un formato JPG a color, como objeto de estudio y para más fácil descripción es necesario pasarla a escala de grises al momento de procesar la imagen y almacenarla en una base de datos anotada, se diseñaron diferentes funciones y procedimientos en MatLab 2015a.

La obtención de los momentos estadísticos es una ventaja cuando hay gran cantidad de datos individuales de una imagen puede ser molesto e inoperativo, por lo que se hace necesario realizar un resumen de cuatro características fundamentales tales como moda, desviación estándar, media, curtosis que permita tener una idea global de la imagen y así poder clasificar nuestras telas con dichas característica mediante los métodos de aprendizaje maquina.

#### **4.1. Entrenamiento de SVM utilizando los descriptores obtenidos por las transformadas FFT, wavelet, SSFT.**

El objetivo es evaluar dos técnicas de aprendizaje supervisado utilizando tres descriptores tiempo frecuencia. A continuación se mostraran los diferentes resultados.

##### **4.1.1. Máquinas de vectores de soporte utilizando la transformada de Fourier.**

Se implementa un algoritmo en MatLab para sacar las características de la imagen utilizando la FFT , a esta transformada se le calculo los momentos estadísticos( moda, media, desviación estándar y curtosis) creando un archivo .MAT, donde se guardan los descriptores con sus respectivas clases en una matriz con una dimensión de  $500 \times 5$ . Ver figura(6)

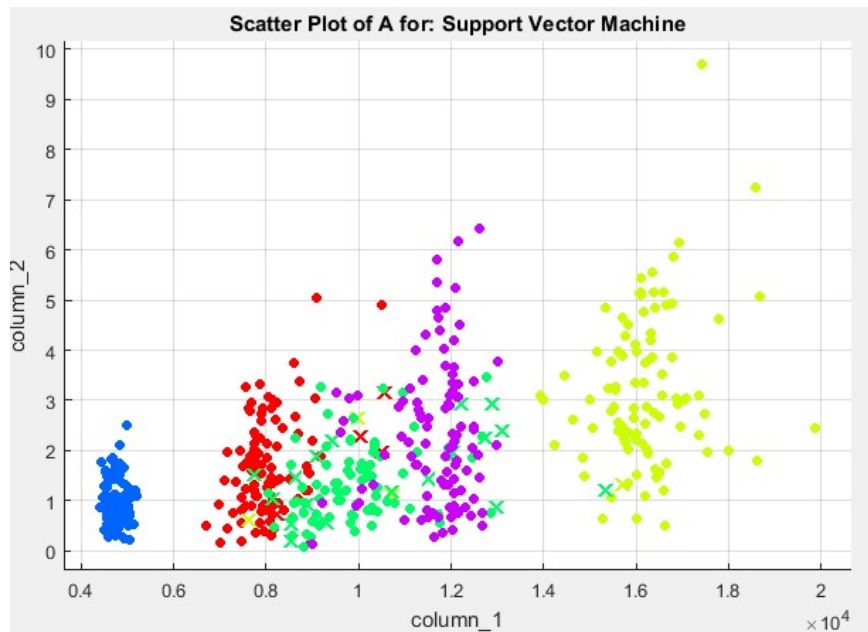


Figura 6: SVM diagramas de dispersión FFT

La descripción dada por los datos de los vectores de soporte es capaz de formar una frontera de decisión alrededor del dominio de los datos de aprendizaje con muy poco o ningún conocimiento de los datos fuera de esta frontera. Se implementa la matriz de confusión en máquinas de soporte vectorial de 5 clases de telas diferentes entre 500 imágenes en una dimensión lineal y se muestran los resultados. Ver figura(7)

**Confusion Matrix for: Support Vector Machine**

True class	1	96 19.2%	0 0.0%	4 0.8%	0 0.0%	0 0.0%
	2	0 0.0%	97 19.4%	3 0.6%	0 0.0%	0 0.0%
	3	8 1.6%	1 0.2%	82 16.4%	0 0.0%	9 1.8%
	4	0 0.0%	0 0.0%	0 0.0%	100 20.0%	0 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100 20.0%
		1	2	3	4	5
		Predicted class				

Figura 7: Separación lineal SVM, matriz de confusión FFT

En la figura (7) se observa la matriz de confusión lineal SVM utilizando la FFT, se puede apreciar que la clase tres presenta el mayor error de clasificación con el 18 %, se evidencia que la maquina presenta errores de clasificación para la clase cinco 9 %, para la clase uno 8 % y la clase dos 1 %, mientras las clases cuatro y cinco las clasifica con un 100 % de acierto.

**Confusion Matrix for: Support Vector Machine**

True class	1	95 19.0%	0 0.0%	5 1.0%	0 0.0%	0 0.0%
	2	0 0.0%	97 19.4%	3 0.6%	0 0.0%	0 0.0%
	3	6 1.2%	1 0.2%	87 17.4%	0 0.0%	6 1.2%
	4	0 0.0%	0 0.0%	0 0.0%	100 20.0%	0 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100 20.0%
		1	2	3	4	5
		Predicted class				

Figura 8: Separación cuadrática SVM, matriz de confusión FFT

En la figura (8) se observa la matriz de confusión cuadrática SVM utilizando la FFT, se puede apreciar que la clase tres presenta el mayor error de clasificación con el 13 %, se evidencia que la maquina presenta errores de clasificación para clase cinco 6 %, para la clase uno 6 % y la clase dos 1 %, mientras las clases cuatro y cinco las clasifica con un 100 % de acierto.

**Confusion Matrix for: Support Vector Machine**

True class	1	91 18.2%	0 0.0%	9 1.8%	0 0.0%	0 0.0%
	2	0 0.0%	97 19.4%	3 0.6%	0 0.0%	0 0.0%
	3	9 1.8%	1 0.2%	82 16.4%	0 0.0%	8 1.6%
	4	0 0.0%	0 0.0%	0 0.0%	100 20.0%	0 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100 20.0%
		1	2	3	4	5
		Predicted class				

Figura 9: Separación cubica SVM, matriz de confusión FFT

En la figura (9) se observa la matriz de confusión cubica SVM utilizando FFT, se puede apreciar que la clase tres presenta el mayor error de clasificación con el 18 %, se puede evidenciar que la maquina presenta errores de clasificación para la clase cinco 8 %, para la clase uno 9 % y la clase dos 1 %, mientras las clases cuatro y cinco las clasifica con un 100 % de acierto.

#### 4.1.2. Maquinas de vectores de soporte utilizando la transformada de Wavelet

Se aplican máquinas de vectores de soporte a la transformada de Wavelet en un sistema automático de verificación de clases de telas, por medio de visión por computador, donde se evalúa su desempeño y en la comparación de éste con otras técnicas de clasificación actualmente empleadas. La metodología consiste en realizar una base de fotos de telas, que sea representativa en cuanto a su clase. Posteriormente en procesar los datos para formar los modelos deseados, para cada Tipo de tela, y la validación de los mismos mediante de diagramas de dispersión y matrices confusión. El objetivo es observar el comportamiento del sistema ante una base de datos anotada de 500 imágenes. Ver figura(10).

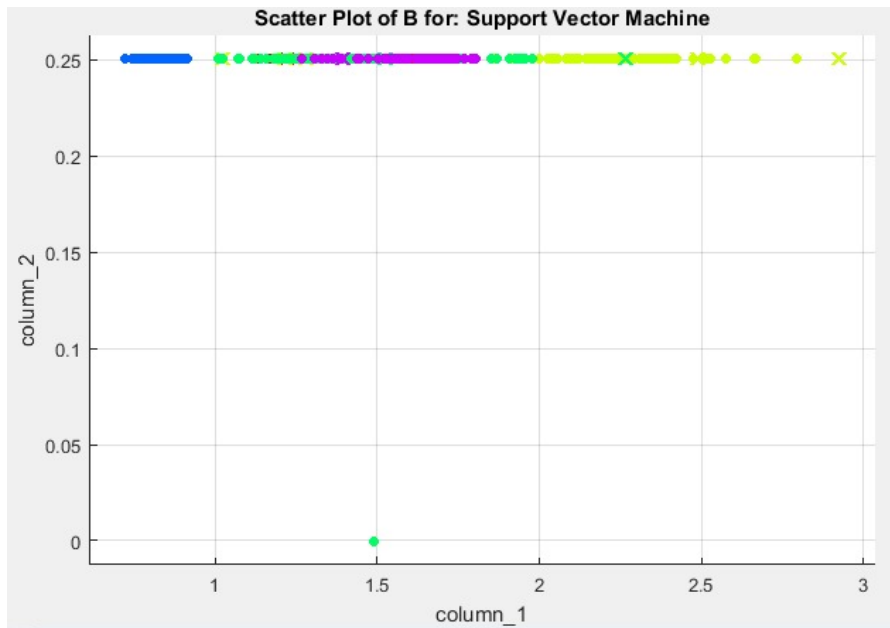


Figura 10: SVM diagramas de dispersión Wavelet

Se observa la matriz de confusión máquinas de vectores de soporte clasifican los datos dependiendo de sus características, como en este caso media, moda, desviación estándar, curtosis, donde a pesar de tener algunas telas muy parecidas la máquina de soporte hacer la parte de clasificación de una manera muy efectiva. Ver figura(11).

**Confusion Matrix for: Support Vector Machine**

True class	1	98 19.6%	0 0.0%	2 0.4%	0 0.0%	0 0.0%
	2	0 0.0%	96 19.2%	3 0.6%	0 0.0%	1 0.2%
	3	1 0.2%	3 0.6%	94 18.8%	0 0.0%	2 0.4%
	4	0 0.0%	0 0.0%	0 0.0%	100 20.0%	0 0.0%
	5	2 0.4%	0 0.0%	0 0.0%	0 0.0%	98 19.6%
			1	2	3	4
		Predicted class				

Figura 11: Separación lineal SVM matriz de confusión Wavelet

En la figura (11) se observa la matriz de confusión lineal SVM utilizando Wavelet, se puede apreciar que la clase tres presenta el mayor error de clasificación con el 6 %, se evidencia que la maquina presenta errores de clasificación para clase cinco 2 %, para la clase uno 1 % y la clase dos 3 %, mientras la clase cuatro se clasifica con un 100 % de acierto.



**Confusion Matrix for: Support Vector Machine**

True class	1	99 19.8%	0 0.0%	1 0.2%	0 0.0%	0 0.0%
	2	0 0.0%	97 19.4%	3 0.6%	0 0.0%	0 0.0%
	3	1 0.2%	1 0.2%	98 19.6%	0 0.0%	0 0.0%
	4	0 0.0%	0 0.0%	0 0.0%	100 20.0%	0 0.0%
	5	0 0.0%	0 0.0%	1 0.2%	0 0.0%	99 19.8%
		1	2	3	4	5
		Predicted class				

Figura 12: Separación cuadrática SVM matriz de confusión Wavelet

En la figura (12) se observa la matriz de confusión cuadrática SVM utilizando Wavelet, se puede apreciar que la clase dos presenta el mayor error de clasificación con el 3 %, se evidencia que la maquina presenta un error de clasificación para la clase tres 3 %, mientras la clase cuatro se clasifica con un 100 % de acierto.

**Confusion Matrix for: Support Vector Machine**

True class	1	99 19.8%	0 0.0%	1 0.2%	0 0.0%	0 0.0%
	2	0 0.0%	97 19.4%	3 0.6%	0 0.0%	0 0.0%
	3	0 0.0%	2 0.4%	97 19.4%	0 0.0%	1 0.2%
	4	0 0.0%	0 0.0%	0 0.0%	100 20.0%	0 0.0%
	5	2 0.4%	0 0.0%	1 0.2%	0 0.0%	97 19.4%
		1	2	3	4	5
		Predicted class				

Figura 13: Separación cubica SVM matriz de confusión Wavelet

En la figura (13) se observa la matriz de confusión cubica SVM utilizando Wavelet, se puede apreciar que la clases que presenta el mayor error de clasificación son :

- Se puede apreciar que la clase dos presenta un error de clasificación con el 3 %, se evidencia que la maquina presenta un error de clasificación para la clase tres un 3 %.
- Se puede apreciar que la clase tres presenta un error de clasificación con el 3 %, se evidencia que la maquina presenta un error de clasificación para la clase cinco un 1 % y con la clase dos un 2 %.
- Se puede apreciar que la clase cinco presenta un error de clasificación con el 3 %, se evidencia que la maquina presenta un error de clasificación para la clase tres un 1 % y con la clase uno un 2 %.
- La clase cuatro no genera ningún error.

#### 4.1.3. Maquinas de vectores de soporte utilizando la transformada de Fourier corta en espacio (SSFT)

La transformada de Fourier corta en espacio SSFT. De este modo sacar el diagrama de dispersión por máquinas de vectores de soporte, donde se puede observar cómo se superponen las 5 clases, que son los cinco tipos de telas diferentes. Ver figura(14)

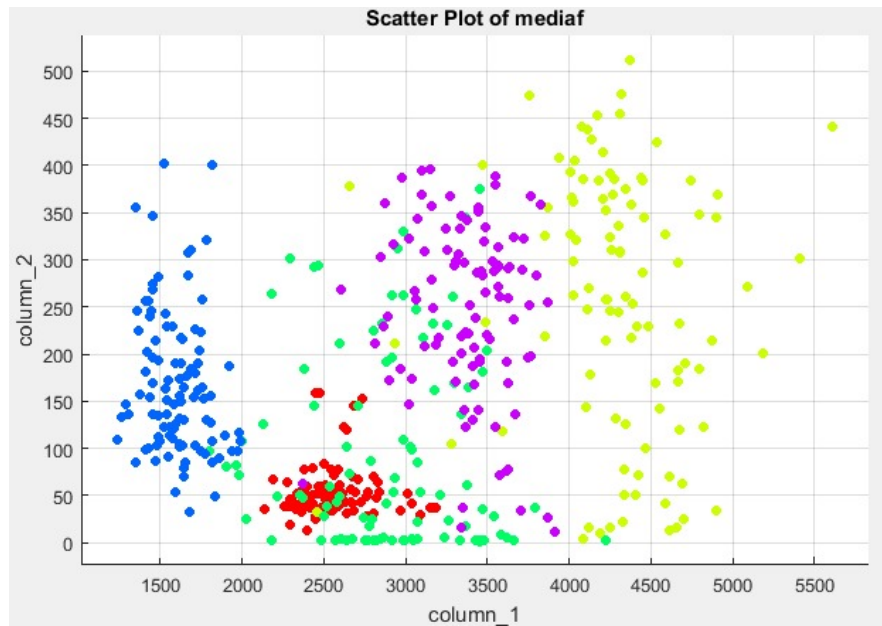


Figura 14: SVM Diagrama de dispersión para SSFT

Para observar un mejor resultado y verlo de una forma más precisa se saca la matriz de confusión donde claramente se puede ver como se separaron las telas y error entre cada una. Ver figura(15).




Figura 15: Separación lineal SVM matriz de confusión SSFT

En la figura (15) se observa la matriz de confusión lineal SVM utilizando SSFT, se puede apreciar que la clase tres presenta el mayor error de clasificación con el 8%, se evidencia que la maquina presenta errores de clasificación para la clase cinco 3%, para la clase uno 5%, mientras las clases uno, cuatro y cinco las clasifica con un 100% de acierto.

**Confusion Matrix for: Support Vector Machine**

True class	1	100 20.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%
	2	1 0.2%	98 19.6%	1 0.2%	0 0.0%	0 0.0%
	3	5 1.0%	0 0.0%	94 18.8%	0 0.0%	1 0.2%
	4	0 0.0%	0 0.0%	0 0.0%	100 20.0%	0 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100 20.0%
		1	2	3	4	5
		Predicted class				

Figura 16: Separación cuadrática SVM matriz de confusión SSFT

En la figura (16) se observa la matriz de confusión cuadrática SVM utilizando SSFT, que la clase que más se confunde es la tercera, generando un error de 6%, la cual se confunde con la clase cinco 1% y con la clase uno 5%, mientras con las clases uno, cuatro y cinco no genera ningún error.

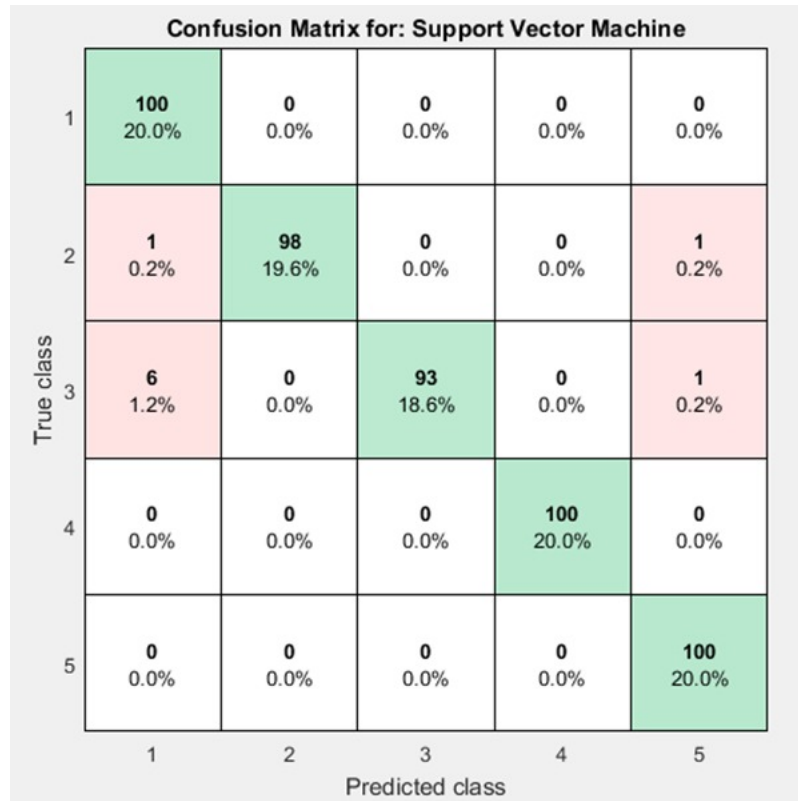


Figura 17: Separación cubica SVM matriz de confusión SSFT

En la figura (17) se observa la matriz de confusión cubica SVM para SSFT, se puede apreciar que la clase tres presenta el mayor error de clasificación con el 7 %, se evidencia que la maquina presenta errores de clasificación para la clase cinco 1 %, para la clase uno 6 % , mientras las clases uno, cuatro y cinco las clasifica con un 100 % de acierto.

#### 4.2. Comparación de las transformadas por SVM

De las matrices de confusión anteriores se puede apreciar que:

- Para la FFT las matrices de confusión lineal, cuadrática y cubica. Se aprecia que la clase tres es la que genera mayor error de clasificación al compararla con los otros dos descriptores, mientras las clases cuatro y cinco presentan un porcentaje de clasificación del 100 % de acierto .
- Utilizando la transformada Wavelet las matrices de confusión lineal, cuadrática y cubica. Se observa que las clases uno, dos, tres y cinco presentan un error de clasificación entre el 1 % y 3 % , mientras la clase cuatro no presenta porcentaje de error en la clasificación.
- Para la SSFT las matrices de confusión lineal, cuadrática y cubica. Se evidencia que el error de clasificación se encuentra en la clase tres mientras las otras clases presentan un error menor o igual a 3 %.

- La transformada SSFT es el descriptor que presenta mejor clasificación, lo cual se puede observar al comparar las diferentes matrices de confusión.

A continuación realizar un análisis comparativo de los métodos implementados. Ver cuadro(2).

SVM			
Descriptor	Eficiencia		
	Lineal	Cuadrática	Cúbica
FFT	95	96.4	94.8
Wavelet	97.2	98.2	97.4
SSFT	97.8	98.4	98.2

Tabla 2: Resultados de los descriptores en máquinas de soporte vectorial

- En el cuadro anterior se puede observar que el método que presenta mejor porcentaje de clasificación es el descriptor SSFT con el SVM cuadrático el cual es 98.4 %, mientras el método que presenta menor clasificación es el descriptor FFT con la SVM lineal el cual es 95 %.

### 4.3. Entrenamiento de RNA utilizando los descriptores obtenidos por las transformadas FFT, Wavelet, SSFT.

Para el entrenamiento utilizando RNA se implementaron 10 capas ocultas neuronas. Y se utilizo el algoritmo de backpropagation. A continuación se van a mostrar los diferentes entrenamientos.

#### 4.3.1. RNA con la Transformada de Fourier

Para el método de separación de datos con la transformada de Fourier se implementó redes neuronales que muestra su resultado por medio de matrices de confusión, y otras herramientas estadísticas de separación de datos.

Para implementar las redes neuronales para los 4 métodos estadísticos(media, moda, curtosis, desviación estándar), que recrean la imagen de los descriptores en la transformada de Fourier , se presenta el modelo de la red neuronal, donde se emplea una entrada de cuatro parámetros y solo 10 capas de neuronas que es un estándar para esta base de datos, se encontró una matriz de 5\*5 como se visualiza en la imagen. Ver figura(18)




Figura 18: RNA para los descriptores de la FFT.

Se puede observar las 4 matrices de confusión de las redes neuronales, para los descriptores de la transformada de Fourier, la matriz de entrenamiento, la matriz de validación de datos, el test de aproximación que emplea para sacar los datos y la verdadera matriz de confusión, que da el resultado total de los datos obtenidos por el análisis de las 10 capas de la neurona, con una entrada de 4 parámetros. Ver figura(19)

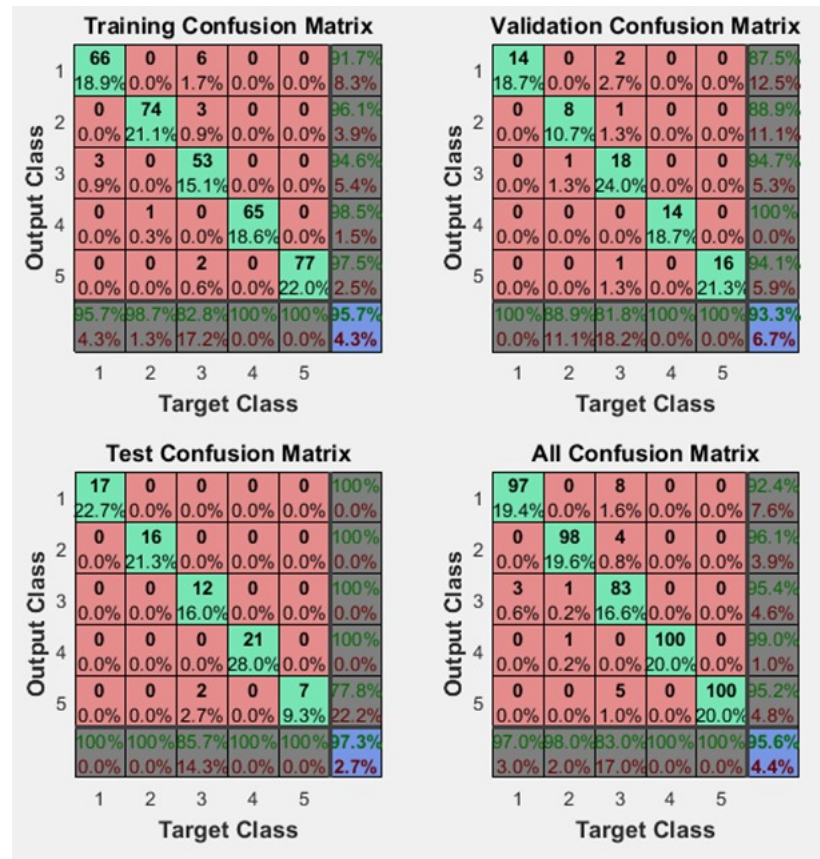


Figura 19: Matriz de confusión RNA para FFT

Se observa en la ultima matriz de confusión verdadera el error total de separación de datos con un porcentaje 4.4 % para la FFT.

#### 4.3.2. RNA con Transformada de Wavelet

En la implementación de redes neuronales para los parámetros estadísticos(media, moda, curtosis, desviación) y para los tres métodos de mapeo(vertical, horizontal, diagonal) que implementa la transformada de Wavelet para un total de 12 entradas que recrean la imagen de los descriptores que se implementaron en la transformada de wavelet . Solo 10 capas de neuronas que es un estándar para esta base de datos, se encontró una matriz de 5\*5 como se visualiza en la imagen.Ver figura(20)






Figura 20: RNA para los descriptores de la wavelet

Se puede observar la matriz de confusión de las redes neuronales, que muestra 4 matrices, la matriz de entrenamiento, la matriz de validación de datos, el test de aproximación que emplea para sacar los datos y la verdadera matriz de confusión, que da el resultado total de los datos obtenidos por el análisis de las 10 capas de las neuronas. Ver figura(21)

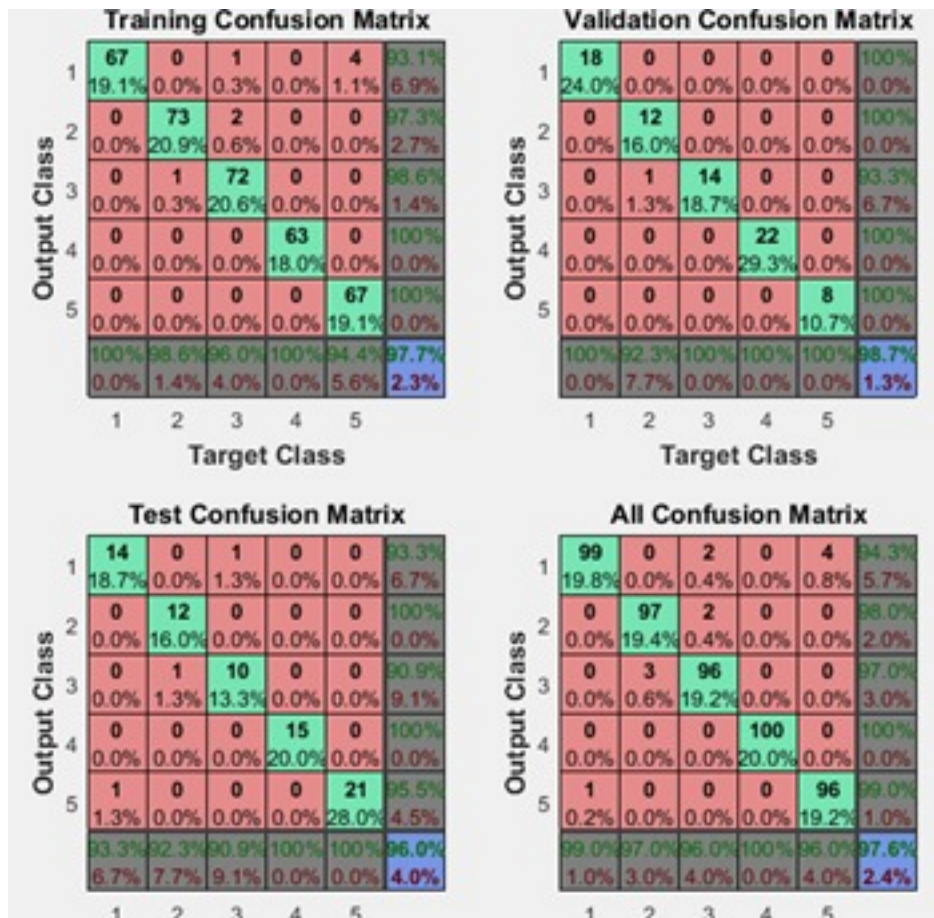


Figura 21: Matriz de confusión RNA Para las Waveles

Se observa en la ultima matriz de confusión verdadera el error total de separación de datos con un porcentaje 2.4 % para la Wavelet.




Figura 22: RNA para la para los descriptores de la SSFT

#### 4.3.3. RNA con Transformada de Fourier corta en espacio (SSFT)

Como se explico en la metodologia la SSFT divide cada imagen en 16 partes iguales y para cada ventana se calculan la FFT y luego los momentos estadísticos, obteniendo una matriz 64x500. ver figura(22)

Se puede observar la matriz de confusión de las redes neuronales, para los descriptores de la transformada de Fourier corta en espacio, que muestra 64 métodos estadísticos que sirven de descripción para las matrices de confusión. ver figura(23)

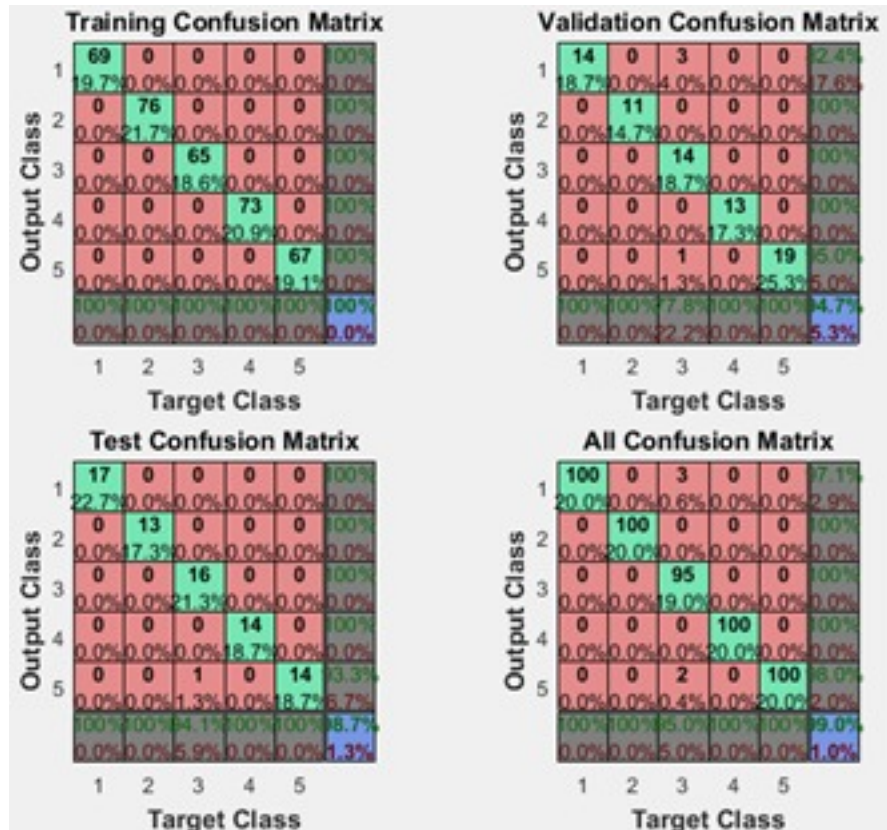


Figura 23: Matriz de confusión RNA para SSFT

Se observa en la ultima matriz de confusión verdadera el error total de separación

RNA			
	FFT	Wavelet	SSFT
Mejor rendimiento de validación	0.03909	0.017759	0.0036193
Gradiente	0.015402	0.0026002	0.002104
Error histograma	0.04624	0.01798	0.05344
Iteraciones	27	42	28
Componentes descriptores	4	12	64
Comprobaciones de validación	6	6	6

Tabla 3: Datos de los descriptores que estimen el error en RNA

de datos con un porcentaje 1 % para la SSFT.

#### 4.4. Comparación de las transformadas por RNA

Se puede concluir que a menor numero de iteraciones y de características de los descriptores el porcentaje de error es mayor. Que a un numero de iteraciones normales y mayor iteraciones el método clasifica mejor que los otros dos y cuando el numero de iteraciones y el numero de características implementadas son intermedios el error se comporta de forma estable es decir ni muy bien, ni muy mal.

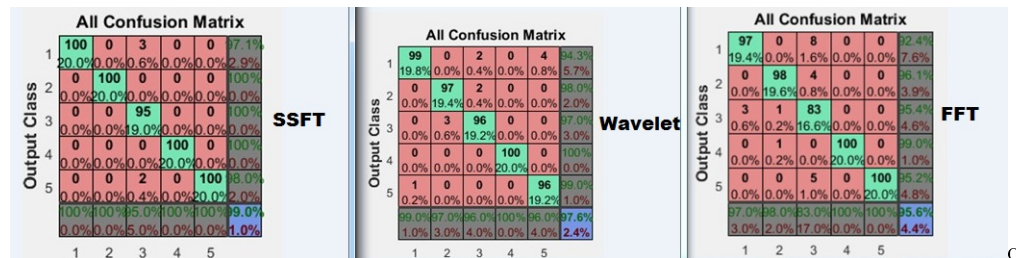


Figura 24: Matriz de conjunción de los diferentes métodos en RNA

Para un correcto análisis se observa la matriz de confusión para los tres descriptores por redes neuronales. Se visualiza las cinco clases manejadas en cada matriz con su respectivo descriptor, donde se muestra el error que hay entre cada clase y el error final de separación de todas las clases donde se evidencia que la SSFT tiene el mejor comportamiento presentando un error del 1%. Ver figura(24)

#### 4.5. Comparación entre SVM y RNA

RNA Consiste en un conjunto de elementos simples de procesamiento llamados nodos o neuronas conectadas entre sí, que tienen un valor numérico modificable su función consiste en sumar los valores de las entradas de las matrices en este caso usando cuatro vectores como: media, moda, desviación estándar, curtosis, más la clase para el caso de la transformada rápida de Fourier (FFT). Trece vectores para la transformada de Wavelet que sacan los parámetros estadísticos como: vertical, horizontal, y diagonal más la clase y Sesenta y cinco vectores para la transformada de Fourier corta en espacio (SSFT) ya

que la imagen está dividida en 16 ventanas iguales, estas matrices son la entrada de cada descriptor.

El análisis de la evolución temporal de la productividad sobre la base de datos creada, permite averiguar la eficiencia en separación de clases por las RNA y hacer una comparación con las máquinas de soporte vectorial que pertenecen a la familia de clasificadores lineales. Mediante una función matemática denominada kernel. Realizan un mapeo de los vectores de entrada para determinar la linealidad o no de los casos los cuales serán integrados a los multiplicadores de Lagrange para minimizar el error en la separación de las clases de telas ya que tienen mucha capacidad de generalización de datos. Al mismo tiempo, el uso de las funciones kernel muestra una gran eficiencia en el resultado de la predicción.

Error de clasificación %			
Descriptores	SSFT	Wavelet	FFT
RNA	1 %	2.4 %	4.4 %
SVM	1.4 %	1.6 %	4.2 %

Tabla 4: Cuadro comparativo

En el cuadro(4). Se puede observar que en los tres descriptores propuestos por medio de máquinas de aprendizaje automático para SVM utilizando la FFT y Wavelet el error final es menor, mientras que para SSFT utilizando RNA muestra un porcentaje de acierto menor, debido a que en SSFT el número de características que hay es mucho mayor a los otro dos descriptores, hace que el método tenga un mejor comportamiento y sea más eficiente para redes neuronales.

## 5. CONCLUSIONES, APORTES Y RECOMENDACIONES

- Por medio de las transformadas tiempo frecuencia y sus respectivos momentos estadísticos se logra obtener características relevantes y separables entre las diferentes telas, permitiendo así obtener unos descriptores eficientes que garantizan una clasificación confiable.
- De los resultados obtenidos se puede apreciar que el algoritmo SVM presenta mayor porcentaje de acierto al utilizar el método SVM cuadrático con el descriptor SSFT obteniendo un 98.4% de éxito.
- Las RNA con el descriptor SSFT se obtuvo un 99% de acierto. Se observa que a mayor características y a un número de iteraciones de 28 es el punto medio entre las otras dos transformadas, clasifica mejor.
- Al realizar un análisis comparativo entre SVM y RNA se observa que el mejor método de clasificación es el que utiliza el descriptor SSFT y el método de aprendizaje RNA ya que presenta un error de clasificación del 1%.

## BIBLIOGRAFÍA

- [1] Pineda de Cuadros, N. E. (2009). Primera industria textil de algodón en Colombia, 1884-1905. Compañía Industrial de Samacá "Fábrica de hilados y tejidos de algodón". *HiSTOReLo. Revista de Historia Regional y Local*, 1(2), 136-168.
- [2] VARGAS, Nestor Andrés González. por computadora para la medición de distancia e inclinación de obstáculos para robots móviles. *Ingeniería y universidad*, 2005, vol. 9, no 2, p. 125-134.
- [3] Sarría, A. F. (2007). Estudio de técnicas basadas en la transformada Wavelet y optimización de sus parámetros para la clasificación por texturas de imágenes digitales (Doctoral dissertation, Universitat Politècnica de València).
- [4] Malvar, H. S., & Staelin, D. H. (1989). The LOT: Transform coding without blocking effects. *Acoustics, Speech and Signal Processing, IEEE Transactions on*, 37(4), 553-559.
- [5] CÁRDENAS, L. J., et al. Representación paramétrica de la transformada de Fourier de tejidos textiles. *Ingeniería y ciencia*, 2007, no 5, p. 135-144.
- [6] <sup>o</sup>Betancourt, G. A. (2005). Las máquinas de soporte vectorial (SVMs). *Scientia et Technica*, 1(27).
- [7] Cortés, J. A., Medina, F. A., & Chaves, J. A. (2007). Del análisis de análisis de fourier. *Scientia et Technica*, 1(34).
- [8] Juan, R. Q., & Mario, C. M. Redes neuronales artificiales para el procesamiento de imágenes, una revisión de la última década.
- [9] Larrotta, D. M. B. (2004). Aplicación de la transformada Wavelet Discreta en el filtrado de señales bioeléctricas. *Umbral Científico, Fundación Universitaria Manuela Beltrán, Bogotá, Colombia*, 92-98
- [10] Faundez, P., & Fuentes, A. (1999). *Procesamiento Digital de Señales Acústicas utilizando Wavelets*. Memoria de titulación de Ingeniería Acústica. Universidad Austral de Chile. Valdivia, Chile.