

**SUPPORT VECTOR MACHINE FOR DETECTING TEXTILE DEFECTS,  
USING FEATURES SPATIAL OF TEXTURE****MÁQUINA DE VECTORES DE SOPORTE PARA LA DETECCIÓN DE  
DEFECTOS TEXTILES EMPLEANDO CARACTERÍSTICAS ESPACIALES DE  
TEXTURA****Ing. Duber Martínez Torres, Ing. Sergio Orjuela****Universidad Antonio Nariño, Colombia**  
E-mail: duber01@yahoo.com, seraleov@telin.ugent.be

**Abstract:** This paper presents the results obtained by using a classifier with Support Vector Machines for detecting textile defects in fabrics. In order to obtain the necessary texture features for the detection, four different texture analysis methods were used. The results show the validity of the scheme implemented for the detection of five of the most common types of defects.

**Resumen:** En este trabajo se presentan los resultados obtenidos al emplear un clasificador con Máquinas de Vectores de Soporte para la detección de defectos en telas sin estampar. Se utilizan cuatro técnicas espaciales para análisis de textura que junto a un grupo de descriptores estadísticos permiten conformar las características necesarias para la detección. Los resultados muestran la validez del esquema implementado para la detección de cinco de los tipos más frecuentes de defectos.

**Keywords:** Image Processing, image object recognition, pattern recognition.

**1. INTRODUCCIÓN**

Dentro del proceso textil, una primera etapa es la producción de telares en crudo, que corresponde a telas sin ningún tipo de estampado y es en este punto donde se deben detectar los diferentes tipos de defectos en el tejido. En países como Colombia, muchas de estas tareas de inspección y control de calidad son realizadas por operarios, lo cual conlleva a la inexactitud en los resultados obtenidos por factores como: la velocidad con que pasa la tela bajo revisión, la amplia área que debe ser abarcada, el cansancio físico y agotamiento visual que esta actividad implica, entre otros. Para el trabajo, se emplearon muestras textiles suministradas por empresas textiles del departamento del Tolima-Colombia, dentro de ellas, se seleccionaron los principales defectos que

se presentan durante el proceso de fabricación. Algunos de estos defectos son apenas perceptibles a simple vista, lo que los hace difíciles de detectar. Dada la naturaleza de la superficie de los tejidos, los defectos aparecen como una variación de la textura, razón principal por la cual las técnicas de análisis de textura han sido ampliamente empleadas para este tipo de aplicaciones (Habit et al., 2004), (Pérez et al., 2007). Existen diversos enfoques para la extracción de las propiedades de textura: espaciales, espectrales, estructurales, basadas en modelo, basadas en color. (Kulak, 2002), (Ralló et al., 2003).

En este trabajo se explora si algunas de las técnicas *espaciales* más comúnmente empleadas, junto con un clasificador apropiado permiten detectar los defectos presentes en las muestras adquiridas. Se

hizo la selección de las técnicas *espaciales* dado que presentan las condiciones de velocidad y complejidad apropiadas para su implementación en un sistema de tiempo real.

En trabajos previos han empleado clasificadores principalmente basados en Redes Neuronales Artificiales (Islam et al., 2006). En este trabajo se emplea como clasificador una Máquinas de Vectores de Soporte SVM (por sus siglas en inglés Support Vector Machines), que en los últimos años, han mostrado ser una herramienta muy poderosa en la clasificación (Kwang et al., 2002). Se parte de una descripción de las imágenes adquiridas y la plataforma de captura empleada, seguidamente se realiza una explicación de las diferentes técnicas espaciales de análisis de textura implementadas para la extracción de las características así como del clasificador con SVM. En la última sección se indican los resultados obtenidos de acuerdo con los diferentes tipos de defectos y las distintas técnicas implementadas.

## 2. DESCRIPCIÓN DEL BANCO DE PRUEBAS

### 2.1 Imágenes de Prueba

Las imágenes que conforman el banco de pruebas para la detección de defectos, fueron adquiridas a partir de muestras de tejido representativas de la industria textil de la región. Fueron considerados cinco tipos de defectos: defectos de barrado, defectos por manchas, defecto de mota tejida, defecto de mariposeo y defecto por piques. La Fig. 1. corresponde a imágenes de los respectivos defectos en el orden anteriormente expuesto.

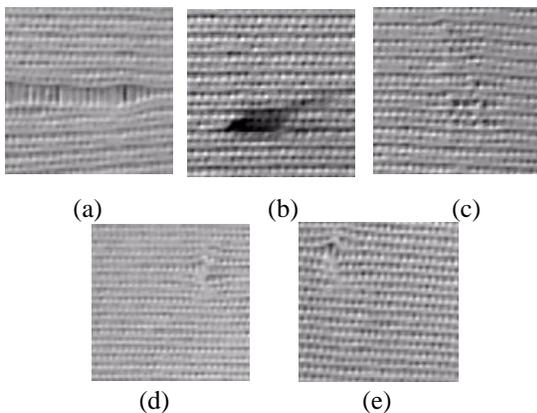


Fig. 1. Tipos de defectos. (a) defecto de barrado, (b) defecto de mancha, (c) defecto de mota tejida, (d) defecto de mariposeo y (e) defecto por piques

### 2.2 Plataforma de Captura

Las muestras obtenidas corresponden a tejidos sin estampar tipo tubular como se indica en la Fig 2. Para la captura se implementó la plataforma que se muestra en la Fig. 3. que permita emular algunas de las condiciones de la máquina tejedora.



Fig. 2. Tejido Tubular Fig. 3. Plataforma

Las imágenes se capturaron con una resolución de 640x480 y durante el preprocesamiento fueron divididas en cuadrículas de 100x100 sobre las cuales se busca la detección de los defectos.

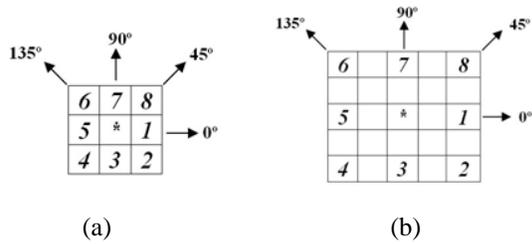
Para el entrenamiento del clasificador se emplearon un total de 500 imágenes, 100 por cada tipo de defecto y para la validación se emplearon 1000 imágenes, 200 por cada tipo de defecto.

## 3. TÉCNICAS DE ANÁLISIS DE TEXTURA IMPLEMENTADAS

En un sentido general, la textura hace referencia a las características y apariencia de la superficie de un cierto objeto, de acuerdo con el tamaño, forma, densidad, arreglo y proporción de los elementos estructurales que la constituyen. Se cuenta con diferentes enfoques para extraer la información a partir de la textura de la imagen (Turceryan y Jain, 1993). En este trabajo se explora uno de estos enfoques, basado en las propiedades espaciales de la imagen y la distribución espacial de las variaciones de tono dentro de un grupo de píxeles de resolución. Se exploran cuatro técnicas espaciales para la extracción de características, a partir de la textura. A continuación se realiza una breve descripción de cada una.

### 3.1 Matriz de Concurrencia de Niveles de Gris

La matriz GLCM por sus siglas en inglés (*Grey Level Co-occurrence Matrix*) es conformada como un histograma de dos dimensiones, donde se indica la frecuencia en que aparece una cierta relación entre pares de píxeles para una distancia y orientación dada. Se establecen típicamente 4 orientaciones  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  y  $135^\circ$  para distancias de 1, 2, etc. píxeles de separación.

Fig. 4. Píxeles vecinos. (a)  $d=1$ , (b)  $d=2$ 

En la imagen de la Fig. 4 (a), se indican los píxeles vecinos tomando como referencia una distancia  $d=1$ . Para una orientación de  $0^\circ$  los píxeles a considerar son los de la posición 1 y 5. Para la orientación de  $45^\circ$  los píxeles 4 y 8. En la Fig. 4 (b) se toma como referencia una distancia  $d=2$ , con los píxeles 1,5 y 4,8 para las orientaciones  $0^\circ$  y  $45^\circ$  respectivamente.

Es posible conformar una matriz de GLCM para cada combinación distancia-orientación. Dicha matriz se conforma de la siguiente manera: La imagen original se cuantifica para un total de  $N_g$  niveles de gris. Se genera una matriz de  $N_g$  filas y  $N_g$  columnas. Cada celda indica el número de veces que una determinada pareja de niveles de gris se repite al recorrer la imagen cuantificada, en la orientación y distancia determinada.

$N_g$	$N_g$	1	2	...	m	...	$N_g$
1				...		...	
2				...		...	
...				...		...	
k				...	200	...	
...				...		...	
$N_g$				...		...	

$d=1, \theta=45^\circ$

Fig. 5. Matriz GLCM

En la Fig. 5. se indica la matriz GLCM para una orientación de  $0^\circ$  y distancia  $d=1$ . La celda correspondiente a la fila  $k$ , columna  $m$ , indica que al recorrer la imagen cuantificada, las veces que se encuentra que el vecino del un píxel con nivel de gris  $k$ , para una distancia de 1 píxel con una orientación de  $45^\circ$  tiene un nivel de gris  $m$ , se repite 200 veces.

Con la finalidad de hacer invariable la matriz GLCM respecto al tamaño de la imagen, es necesario normalizarla, para ello primero se vuelve simétrica sumándole su transpuesta, y seguidamente expresándola como una función de

probabilidad, donde a cada celda se le asigna el valor indicado por la ecuación (1), que corresponde a la relación de aparición de un evento entre el número total de posibles eventos.

$$c_{ij} = \frac{V_{ij}}{\sum_{i,j=0}^{N-1} V_{ij}} \quad (1)$$

### 3.1.1 Descriptores de textura empleados

Una vez obtenida la matriz GLCM, se conforma un vector de características cuyos 11 elementos corresponden a los descriptores indicados a continuación (Jiménez, 2002):

Sean:

$c_{ij}$  Término  $i,j$  de la matriz GLCM

$N_g$  Número de niveles de gris

$$\sum_i y \sum_j = \sum_{i=1}^{N_g} y \sum_{j=1}^{N_g}$$

$$\text{Entropía } Ent = -\sum_i \sum_j c_{ij} \log c_{ij} \quad (2)$$

$$\text{Uniformidad } U = \sum_i \sum_j c_{ij}^2 \quad (3)$$

$$\text{Contraste } Con = \sum_i \sum_j |i-j|^2 c_{ij} \quad (4)$$

$$\text{Correlación } Crr = \frac{1}{s_i s_j} \left| \sum_i \sum_j (i-m_i)(j-m_j) c_{ij} \right| \quad (5)$$

Donde

$$m_i = \sum_j c_{ij} \quad m_j = \sum_i c_{ij}$$

$$s_i = \sum_j (i-m_i) c_{ij}$$

$$s_j = \sum_i (j-m_j) c_{ij}$$

**Momento de Diferencia de Orden  $k$ :**

$$Dif = \sum_i \sum_j |i-j|^k c_{ij} \quad (6)$$

**Momento Inverso de Diferencia de Orden  $k$ :**

$$Inv = \sum_i \sum_j \frac{c_{ij}}{|i-j|^k} ; i \neq j \quad (7)$$

$$\text{Máxima Probabilidad } mp = \max_{ij}(c_{ij}) \quad (8)$$

**Homogeneidad Local:**

$$HL = \sum_i \sum_j \frac{c_{ij}}{1 + (i - j)^2} \quad (9)$$

$$\text{Varianza } V = \sum_i \sum_j (i - \mathbf{m})^2 c_{ij} \quad (10)$$

$$\text{Directividad } Dir = \sum_i c_{ii} \quad (11)$$

**Tendencia de Cluster:**

$$TC = \sum_i \sum_j (i + j - 2\mathbf{m})^k c_{ij} \quad (12)$$

### 3.2 Matriz de Secuencia de Longitud de Nivel de Gris GLRLM (Gray Level Run Length Matrix)

Por lo general un número grande de píxeles vecinos del mismo nivel de gris representan una textura rustica, mientras que un reducido número de estos píxeles representa una textura refinada, de tal forma que la longitud de primitivos de textura en diferentes direcciones puede servir como descriptor de textura, donde un primitivo es el máximo conjunto contiguo de píxeles de nivel de gris constantes ubicados en una línea. El método de longitud de secuencias de gris está basado en calcular el número de secuencias de nivel de gris de varias longitudes, donde una secuencia de nivel de gris es un conjunto de puntos de la imagen linealmente adyacentes en una secuencia en una determinada orientación. En la Fig. 6, las dos celdas sombreadas indican una secuencia de longitud 2 en la orientación de 45°.

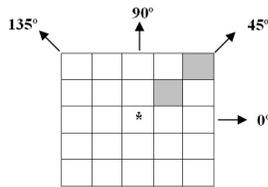


Fig. 6. Secuencia de longitud 2

Long	1	2	...	m	...	L <sub>M</sub>
Nivel						
1			...		...	
2			...		...	
...			...		...	
k			...	10	...	
...			...		...	
N <sub>G</sub>			...		...	

Fig. 7. Matriz GLRLM

Una vez la imagen se ha cuantificado en L<sub>G</sub> niveles de gris, se genera la matriz GLRLM con L<sub>G</sub> filas y L<sub>M</sub> columnas, donde L<sub>M</sub> corresponde a la máxima longitud de la secuencia. Por cada posible orientación (0°, 45°, 90° y 135°) se genera una matriz GLRLM. En la Fig. 7, se indica la conformación de la matriz para una orientación de 0°. El valor 10 que aparece en la celda sombreada indica que para el nivel de gris **k**, se encontraron 10 secuencias de longitud **m** de píxeles consecutivos con el mismo valor **k** en una orientación de 0°.

#### 3.2.1 Descriptores de Textura empleados

Sea  $B(a, r)$  el número de primitivos de la longitud  $r$  y el nivel de gris  $a$ , en alguna dirección  $\mathbf{f}$ ;  $M$ ,  $N$  las dimensiones de la imagen, y  $L$  el número de niveles de gris de la imagen. Sea  $L_m$  la longitud de primitivo máxima en la imagen.

El número total de secuencias  $K$  se obtiene de:

$$K = \sum_{a=1}^L \sum_{r=1}^{L_m} B(a, r) \quad (13)$$

Fueron empleados los siguientes descriptores de textura:

Énfasis de primitivos (Run) largos LRE (Long Run Emphasis):

$$LRE = \frac{1}{K} \sum_{a=1}^L \sum_{r=1}^{L_m} B(a, r) r^2 \quad (14)$$

Énfasis de primitivos (Run) cortos SER (Short Run Emphasis)

$$SER = \frac{1}{K} \sum_{a=1}^L \sum_{r=1}^{L_m} \frac{B(a, r)}{r^2} \quad (15)$$

Uniformidad de nivel de gris GLU (Gray Level Uniformity)

$$GLU = \frac{1}{K} \sum_{a=1}^L \left( \sum_{r=1}^{L_m} B(a, r) \right)^2 \quad (16)$$

Uniformidad de longitud del primitivo (Run) RLU (Run Length Uniformity)

$$GLU = \frac{1}{K} \sum_{r=1}^{L_m} \left( \sum_{a=1}^L B(a, r) \right)^2 \quad (17)$$

Porcentaje de primitivo (Run) RPC (Run Percentage).

$$RPC = \frac{K}{\sum_{n=1}^L \sum_{r=1}^{L_m} r B(a, r)} \quad (18)$$

### 3.3 Matriz de Dependencia de Niveles de Gris de la Vecindad NGLDM (Neighbouring Gray Level Dependence Matrices)

Se buscan características independientes de la orientación, considerando la relación entre un elemento y todos sus vecinos simultáneamente en vez de una sola dirección. Esto elimina la

dependencia angular y reduce el tiempo de cálculo requerido para procesar una imagen. Los parámetros de la matriz son la distancia  $d$  y el umbral  $a$ , de tal forma que se puede obtener una matriz por cada posible combinación de dichos parámetros. La matriz es calculada de la relación de nivel de gris entre cada elemento en la imagen y todos sus vecinos a una cierta distancia  $d$ . La matriz NGLDM es conformada por  $N_G$  filas, correspondiente al número de niveles de gris de la imagen cuantificada y  $N_r$  columnas, donde  $N_r$  es el número de posibles vecinos a un píxel en un rango especificado por  $d$ .

En la Fig. 8 se indica la matriz NGLDM para el caso de una vecindad de distancia  $d=2$ , donde se tienen 16 vecinos para el píxel central Fig 9. El valor 10 que aparece en la celda sombreada indica que al recorrer la imagen, se ha encontrado 10 veces que para un píxel con nivel de gris  $k$ , dicho píxel tenga 8 vecinos cuya diferencia de nivel de gris con el nivel  $k$  sea menor que el umbral  $a$ .

Vecinos	1	2	...	8	...	16
Nivel						
1			...		...	
2			...		...	
...			...		...	
$k$			...	10	...	
...			...		...	
$N_G$			...		...	

Fig. 8. Matriz NGLDM

1	2	3	4	5
16				6
15		*		7
14				8
13	12	11	10	9

Fig. 9. vecindad  $d=2$ 

### 3.3.1 Descriptores de Textura empleados

Se emplearon los siguientes descriptores:

Sea  $Q$  la matriz NGLDM

Énfasis de número pequeño. SNE (*Small Number Emphasis*)

$$SNE = \sum_i \sum_j \left( \frac{Q(i, j)}{j} \right) \quad (19)$$

Énfasis de número Largo LNE (*Large Number Emphasis*)

$$LNE = \sum_i \sum_j (i^2 Q(i, j)) \quad (20)$$

No uniformidad de Número NNU (*Number Non-Uniformity*)

$$NNU = \sum_i \left[ \sum_j Q(i, j) \right]^2 \quad (21)$$

Entropía ENT (*Entropy*)

$$ENT = - \sum_i \sum_j Q(i, j) \log(Q(i, j)) \quad (22)$$

Segundo Momento SM (*Second Moment*)

$$SM = \sum_i \sum_j [Q(i, j)]^2 \quad (23)$$

### 3.4 Medida de Energía de la Textura de Laws

El método de energía de textura para el análisis de textura involucra la aplicación de filtros simples a imágenes digitales (Habit et al., 2004), Laws diseño estos filtros para destacar características de alta energía de textura en imágenes usando como base filtros Gaussianos, la detección de bordes y filtros de tipo Laplaciano, usando una serie de arreglos de píxeles de impulso obtenidos de una combinación de vectores unidimensionales, estos vectores son divididos en tres vectores base:

$$L3 = [1, 2, 1] \quad E3 = [-1, 0, 1] \quad S3 = [-1, 2, 1] \quad (24)$$

Estos vectores representan promedio (*Level*), detección de bordes (*Edge*) y detección de puntos o manchas (*spots*). Es posible obtener vectores de mayor tamaño para analizar una imagen en diferentes escalas, convolucionando los tres vectores base, obteniendo finalmente cinco vectores llamados máscaras de convolución unidimensionales:

$$E5 = [-1, -2, 0, 2, 1], \quad L5 = [1, 4, 6, 4, 1], \\ R5 = [1, -4, 6, -4, 1], \quad S5 = [-1, 0, 2, 0, -1], \\ W5 = [-1, 2, 0, -2, 1] \quad (25)$$

A partir de estas máscaras unidimensionales, se generan 25 máscaras bidimensionales convolucionándolas como se indica en la tabla 1.

Tabla 1: Máscaras de convolución bi-dimensionales

L5L5	E5L5	S5L5	W5L5	R5L5
L5E5	E5E5	S5E5	W5E5	R5E5
L5S5	E5S5	S5S5	W5S5	R5S5
L5W5	E5W5	S5W5	W5W5	R5W5
L5R5	E5R5	S5R5	W5R5	R5R5

Se generan 25 imágenes parciales al aplicar cada máscara sobre la imagen original. Sobre cada una de estas imágenes se aplica el filtro no lineal que se

indica en la ecuación (26). Generando las 25 imágenes parciales indicadas en la tabla 2.

$$New(x, y) = \sum_{i=-1}^1 \sum_{j=-1}^1 |Old(x+i, y+j)| \quad (26)$$

**Tabla 2: Imágenes con filtro no lineal**

L5L5T	E5L5T	S5L5T	W5L5T	R5L5T
L5E5T	E5E5T	S5E5T	W5E5T	R5E5T
L5S5T	E5S5T	S5S5T	W5S5T	R5S5T
L5W5T	E5W5T	S5W5T	W5W5T	R5W5T
L5R5T	E5R5T	S5R5T	W5R5T	R5R5T

Se combinan imágenes con información complementaria como se indica en la ecuación (27).

$$E5L5TR = E5L5T + L5E5T \quad (27)$$

Se obtiene de esta forma 10 imágenes transformadas TRimag sobre las cuales se procede a aplicar los descriptores estadísticos de textura para así formar los vectores de características.

$$Energía = \sum_i \sum_j TRimag(i, j) \quad (28)$$

$$Promedio(\mathbf{m}) = \frac{1}{MN} \sum_i \sum_j TRimag(i, j) \quad (29)$$

$$Varianza = \frac{1}{(M-1)N} \sum_i \sum_j (TRimag(i, j) - \mathbf{m})^2 \quad (30)$$

$$Skewness = \frac{1}{MN} \sum_i \sum_j \frac{(TRimag(i, j) - \mathbf{m})^3}{Var^{3/2}} \quad (31)$$

$$Kurtosis = \frac{1}{MN} \sum_i \sum_j \frac{(TRimag(i, j) - \mathbf{m})^4}{Var^2} \quad (32)$$

#### 4. CLASIFICADOR CON SVM

Se presenta en forma compacta los pasos básicos para la implementación del clasificador con una máquina de vectores de soporte SVM (*Support Vector Machines*).

Se conforma la clase  $C_1$  con los vectores de características de las diferentes imágenes correspondientes a imágenes de textiles en buen estado. Y la clase  $C_2$  conformada con los vectores de características de las imágenes correspondientes a muestras con defectos.

Se selecciona una función Kernel. En este trabajo se empleó la función Gaussiana.

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2s^2}\right) \quad (33)$$

Se resuelve el siguiente problema de optimización:

Maximizar<sub>a</sub>

$$\sum_{i=1}^N \mathbf{a}_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \mathbf{a}_i \mathbf{a}_j y_i y_j K(x_i, x_j) \quad (34)$$

$$\text{Sujeto a: } \sum_{i=1}^N \mathbf{a}_i y_i = 0$$

$$0 \leq \mathbf{a}_i \leq C \quad i = 1, 2, \dots, N$$

Se calcula:

$$\hat{b} = -\frac{1}{2} \sum_{i \in VS} \hat{\mathbf{a}}_i y_i [K(x_i, x_p) + K(x_i, x_n)] \quad (35)$$

Donde:

$x_i$  Vector soporte  $i$

$x_p$  Vector soporte del plano positivo

$x_n$  Vector soporte del plano negativo

Se conforma la función discriminante:

$$f(x) = \sum_{i \in SV} \hat{\mathbf{a}}_i y_i [K(x_i, x) + \hat{b}] \quad (36)$$

Para resolver el problema de optimización se han planteado múltiples soluciones, algunas aparecen referenciadas en (Cristianini y Shawe, 2000). En este trabajo se empleó un algoritmo de programación cuadrática. Para resolver el problema de programación cuadrática es necesario expresar el problema de optimización en forma matricial.

Minimizar<sub>a</sub>

$$\frac{1}{2} \mathbf{a}^T \mathbf{H} \mathbf{a} + f^T \mathbf{a} \quad (37)$$

$$\text{Sujeto a: } A_{eq} \mathbf{a} = 0$$

$$0 \leq \mathbf{a}_i \leq C \quad i = 1, 2, \dots, N$$

Donde

$$\mathbf{H} = \begin{bmatrix} y_1 y_1 K_{11} & y_1 y_2 K_{12} & \dots & y_1 y_N K_{1N} \\ y_2 y_1 K_{21} & y_2 y_2 K_{22} & \dots & y_2 y_N K_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ y_N y_1 K_{N1} & y_N y_2 K_{N2} & \dots & y_N y_N K_{NN} \end{bmatrix} \quad (38)$$

$$K_{ij} = K(x_i, x_j) \quad (39)$$

$$\mathbf{a}^T = [\mathbf{a}_1 \ \mathbf{a}_2 \ \dots \ \mathbf{a}_N] \quad (40)$$

$$A_{eq} = [y_1 \ y_2 \ \dots \ y_N] \quad (41)$$

$$f^T = [-1 \ -1 \ \dots \ -1] \quad (42)$$

## 5. RESULTADOS EXPERIMENTALES

Para la validación de las técnicas se emplearon un total de 2000 imágenes, 1000 de las cuales corresponden a imágenes de muestras en buen estado y 1000 de muestras con defectos, divididas en grupos de 200 imágenes por cada tipo de defecto.

En la tabla 3, se presentan los porcentajes de acierto obtenidos en la clasificación de las diferentes muestras tanto en buen estado como con los tipos de defectos. Cada columna corresponde al resultado del clasificador con SVM y los vectores de características obtenidos por cada una de las cuatro técnicas de análisis de textura implementadas. Así, por ejemplo, el primer valor de la tabla 98.3 indica que de las 400 imágenes (200 de muestras en buen estado y 200 con defecto de barrado) 393 fueron correctamente clasificadas como buenas o como con defecto, al emplear la técnica GLCM. En esta tabla, a partir del promedio se muestra que el mejor desempeño global se obtiene con la NGLDM y el más bajo con LAWS. Sin embargo se observan algunas variaciones en el desempeño relativo de cada técnica respecto al tipo de defecto.

En la tabla 4 se indica el porcentaje de acierto en la detección de los defectos, así por ejemplo, el primer valor 98.5 indica que de las 200 imágenes correspondientes al defecto de barrado, con la técnica GLCM se reconocieron 197 como con defecto y 3 como si no tuviesen defectos. Aunque en promedio NGLDM presenta el desempeño global más alto, sin embargo se observa que esto varía de acuerdo con el tipo de defecto, así por ejemplo, para barrado GLCM presenta el mayor valor, mientras que para piques y mariposeo el mayor valor se obtiene con LAWS.

Estos datos sin embargo no son completos, si no se tiene en cuenta el porcentaje de falsos aciertos, que corresponden a imágenes de muestras en buen estado clasificadas como defectuosas; en la tabla 5 se indica el porcentaje de falsos aciertos. Los menores errores por falsas detecciones se obtienen con GLCM, mientras que los mayores errores se alcanzan con LAWS.

Se observa en todas las tablas que el tipo de defecto que presenta mayor dificultad en su detección es el de mariposeo, esto debido a su pequeño tamaño que puede hacerlo confundir con el tejido normal.

*Tabla 3: Porcentaje de Acierto de Clasificación*

Defecto/Tec	GLC M	GLRM L	NGLD	LAW S
<b>Barrado</b>	98.3	89.5	93.0	86.5
<b>Manchas</b>	94.0	91.5	99.3	73.5
<b>Mota</b>	94.3	86.5	94.3	79.0
<b>Mariposeo</b>	85.3	81.8	86.5	85.3
<b>Piques</b>	94.3	79.3	95.5	90.8
<b>Promedio</b>	<b>93.2</b>	<b>85.7</b>	<b>93.7</b>	<b>83.0</b>

*Tabla 4: Porcentaje de Defectos Detectados*

Defecto/Tec.	GLC M	GLRM L	NGLD	LAW S
<b>Barrado</b>	98.5	91.5	91.0	95.5
<b>Manchas</b>	92.0	91.5	99.5	68.0
<b>Mota</b>	90.0	84.5	92.0	66.0
<b>Mariposeo</b>	71.5	75.5	75.5	88.0
<b>Piques</b>	91.0	68.0	93.0	98.0
<b>Promedio</b>	<b>88.6</b>	<b>82.2</b>	<b>90.2</b>	<b>83.1</b>

*Tabla 5: Porcentaje de Falsos Aciertos*

Defecto/Tec	GLC M	GLRM L	NGLD	LAW S
<b>Barrado</b>	2.0	12.5	5.0	22.5
<b>Manchas</b>	4.0	8.5	1.0	21.0
<b>Mota</b>	1.5	11.5	3.5	8.0
<b>Mariposeo</b>	1.0	12.0	2.5	17.5
<b>Piques</b>	2.5	9.5	2.0	16.5
<b>Promedio</b>	<b>2.2</b>	<b>10.8</b>	<b>2.8</b>	<b>17.1</b>

## 5. CONCLUSIONES

Se construyó una plataforma que permite emular las condiciones de adquisición de muestras textiles en una máquina tejedora tipo tabular. Se adquirieron muestras del sector industrial con los cinco tipos más comunes de defectos con diferentes formas tamaños. Se implementaron cuatro técnicas espaciales de análisis de textura para obtener a partir de éstas, las características que permitan mediante un clasificador basado en una Máquina de Vectores de Soporte detectar la presencia o no de algún tipo de defecto.

Los resultados muestran que el esquema de extracción de características empleando las técnicas espaciales de análisis de textura, junto con el clasificador con Máquinas de Vectores de Soporte presenta un alto índice de acierto en la

detección de defectos, teniendo en cuenta, que algunos de dichos defectos son muy pequeños haciendo difícil su detección. La técnica que presentó el mayor desempeño global es la NGLDM y la de menor desempeño fue LAWS, sin embargo, se destaca el hecho de que algunas de las características de textura extraídas por las diferentes técnicas son complementarias entre sí, de tal forma que algunos defectos se detectan mejor con una técnica que con otra, lo que abre un panorama para trabajos futuros.

## REFERENCIAS

Habib, Hafiz Adnan; Yousaf, Mohammad Haroon; Mohibullah, M. "Modified Laws Energy Descriptor for Inspection of Ceramic Tiles". University of Engineering and Technology Taxila. National Conference on Emerging Technologies, 2004. p137 - 140.

Islam, Atiqu; AKHTER, Shamim; Y MURSALIN, Tumnun. "Automated Textile Defect Recognition System Using Computer Vision and Artificial Neural Networks". Proceedings of World Academy of Science, Engineering And Technology. Volumen 13. May 2006. 6p.

Jiménez, Alvaro. "Análsis de comportamiento de descriptores de la matriz de coocurrencia en la extracción de características de textura en imágenes digitales", Universidad Nacional de Colombia, Manizales, 2002, 63p.

Kulak, Eray. "Analysis Of Textural Image Features For Content Based Retrieval". Submitted to the Graduate School of Engineering and Natural Sciences in partial fulfillment of the requirements for the degree of Master of Science. Sabanci University. 2002. 141p.

Pérez Castilho, Hugo; Sequeira Gonçalves, Paulo Jorge; Caldas Pinto, João Rogério; Limas Serafim, António. "Intelligent Real-Time Fabric Defect Detection. Image Analysis and Recognition". Volume 4633/2007. 2007. P.1297-1307.

Tuceryan M. and A. K. Jain. "Texture Analysis", chapter 2, pages 235-276. World Scientific Publishing Co., 1993.

M. Ralló, M. S. Millán, J. Escofet. "Wavelet based techniques for textile inspection", *Opt. Eng.* 26(2), 838-844 (2003).

Nello Cristianini and John Shawe. "An Introduction to Support Vector Machines" Cambridge University Press. 2000.

Kwang In Kim, Keechul Jung, Se Hyun Park, and Hang Joon. "Support Vector Machines for for Texture Classification", *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 24, no. 11, november 2002.