

ARTICULO ACEPTADO (IN PRESS)

TITULO: DESCRIPTORES ESPACIO-FRECUENCIA PARA IDENTIFICACIÓN AUTOMÁTICA DE PATRONES DE TEXTURA EN PRODUCTOS TEXTILES UTILIZANDO APRENDIZAJE SUPERVISADO

Autores: Arley Bejarano Martínez, Andrés Felipe Calvo Salcedo, Carlos Alberto Henao Baena

Fecha de recepción: 20 de Diciembre de 2017

Fecha de revisión: 21 de Marzo de 2018

Fecha de aprobación: 13 de Abril de 2018

Este es un archivo PDF de un manuscrito inédito que ha sido aceptado para su publicación en la revista Ciencia e Ingeniería Neogranadina (RCIN). Como un servicio a nuestros lectores, estamos proporcionando esta versión inicial del documento. Se realizará revisión de estilo, diseño y diagramación para su publicación final. Tenga en cuenta que durante el proceso de producción se pueden corregir errores de redacción y ortografía, y se incluirán todos los avisos legales que aplican a RCIN.

DESCRIPTORES ESPACIO-FRECUENCIA PARA IDENTIFICACIÓN AUTOMÁTICA DE PATRONES DE TEXTURA EN PRODUCTOS TEXTILES UTILIZANDO APRENDIZAJE SUPERVISADO

Space-Frequency descriptors for automatic identification of texture patterns using supervised learning

Arley Bejarano Martínez. Ingeniero Electrónico. Candidato a Magister en Ingeniería Eléctrica. Docente Catedrático Auxiliar. Grupo de Investigación en Ingeniería Electrónica. Universidad Tecnológica de Pereira. Pereira, Colombia, abejarano@utp.edu.co. ORCID: <https://orcid.org/0000-0002-0470-537X>

Andrés Felipe Calvo Salcedo. Ingeniero Electrónico. Magister en Ingeniería Eléctrica. Docente transitorio tiempo completo. Grupo de Investigación en Ingeniería Electrónica. Universidad Tecnológica de Pereira. Pereira, Colombia, afcervo@utp.edu.co. ORCID: <https://orcid.org/0000-0001-9409-8982>

Carlos Alberto Henao Baena. Ingeniero Eléctrico. Magister en Ingeniería Eléctrica. Gestor Línea de Electrónica y Telecomunicaciones Tecnoparque Nodo Pereira, Centro Atención Sector Agropecuario - SENA, Pereira, Colombia. chenaob@sena.edu.co. ORCID: <https://orcid.org/0000-0001-9873-8211>

ABSTRACT

This article presents an evaluation of frequency space descriptors and texture analysis techniques for the classification of textiles. The work methodology consists of three fundamental stages, characterization, classification and validation. In the characterization stage, descriptors are used, such as the wavelet transform, the Fourier transform, a texture characterization method of the state-of-the-art, such as fractal segmentation for texture analysis (FSTA) and the adaptation of the Fourier Short Transform in space. For the classification stage, the use of three state-of-the-art methods is analyzed, such as the Artificial Neural Networks (ANN), Vector Support Machines (SVM) and the Gaussian Process (GP), the use of linear, Gaussian and polynomial kernels were included in the latter two. To validate the method an annotated database with ten types of fabrics with a total of 1000 photos is built, to which the characterization and classification process is applied by means of a Monte-Carlo experiment. In this stage, random configurations of training (70%) and testing (30%) are generated, obtaining the performance of each classification model. Finally, the confusion matrix is obtained and the success percentages of each experiment are determined. Additionally, a time analysis is made for each of the algorithms, both at the descriptor level and at the classifier level in order to determine the configuration that offers better features and its computational cost.

Keywords: Cloths, time-frequency, Fourier Transform, texture analysis, fractal segmentation, machine learning.

RESUMEN

En este artículo se presenta una evaluación de descriptores espacio frecuencia y técnicas de análisis de texturas, para la clasificación de textiles. La metodología de trabajo consta de tres etapas fundamentales, la caracterización, la clasificación y la validación. En la etapa de caracterización se utilizan descriptores como la transformada Wavelet, la transformada de Fourier, un método de caracterización de textura del estado del arte como lo es segmentación fractal para el análisis de texturas (SFTA) y la adaptación de la Transformada corta de Fourier en espacio. Para la etapa de clasificación se analiza el uso de tres métodos del estado del arte, como lo son las, las Redes Neuronales Artificiales (RNA), Máquinas de Soporte Vectorial (SVM) y el Proceso Gaussiano (GP), a estos dos últimos se les incluyeron el uso de *kernels* lineales, Gaussianos y polinomiales. Para validar el método se construye una base de datos anotada con diez tipos de telas con un total de 1000 fotos, a las cuales se le aplica el proceso caracterización y clasificación por medio de un experimento Montecarlo. En esta etapa se generan configuraciones aleatorias de entrenamiento (70%) y prueba (30%) obteniendo el desempeño de cada modelo de clasificación. Por último, se obtiene la matriz de confusión y se determinan los porcentajes de acierto de cada experimento, adicional se realiza un análisis de tiempos para cada uno de los algoritmos, tanto a nivel de descriptor como a nivel de clasificador con el fin de determinar la configuración que mejores prestaciones presenta y su costo computacional.

Palabras-clave: Textiles, tiempo frecuencia, transformada de Fourier, análisis de textura, segmentación fractal, aprendizaje de máquina,

INTRODUCCIÓN

Debido al alto crecimiento de la industria textil y a los diferentes productos fabricados es necesario diseñar métodos que permitan garantizar la calidad del producto con el fin de lograr ser competitivo en el mercado global, donde la calidad se ha convertido en su eje primordial [5 - 6]. El control de calidad se define como el grado de conformidad del producto con respecto a sus especificaciones. Esta especificación puede ser objetiva y formal, sin embargo, en las fábricas donde se realizan tejido de punto, es un proceso subjetivo y difícil de definir [1].

En la actualidad se fabrican productos textiles para diferentes propósitos, como lo son la protección del frío, la absorción de líquidos, el diseño de modas, entre otros propósitos. A esto se le conoce como tecnología textil y su clasificación varía según el patrón y en muchos casos esto determina la calidad del producto [7]. Con el fin de garantizar calidad en la fabricación de tejido de punto, se han propuesto diferentes métodos para realizar la inspección del producto, que van desde la

revisión por operarios expertos hasta el diseño de sistemas automáticos de inspección [15, 24 - 27].

Los métodos de clasificación manual son ampliamente utilizados en las pequeñas empresas, aunque estos métodos son de baja inversión y fácil implementación, no resultan efectivos para su labor debido a errores humanos como la percepción de colores y texturas. Adicional se debe considerar que la materia prima en este tipo de empresas es diversa y se presenta en grandes cantidades generando desgaste en los operarios propiciando el error.

Dado esta situación se han ideado diferentes técnicas para la identificación de errores en los textiles tales como la inspección a través de máquinas, la cual ha demostrado resultados satisfactorios, sin embargo, su detección es limitado a una pequeña cantidad tipos de telas, además de requerir altos costos de inversión. Otros enfoques proponen el uso de cámaras con el fin de determinar los defectos presentes en las telas por medio de técnicas de visión por computador, resaltando el uso de morfología matemática [18], método fractal [27], redes neuronales artificiales [28], entre otros.

En el estado del arte se han diseñado un gran número de metodologías para el reconocimiento de patrones, sin embargo, muchas de estas estrategias requieren de ambientes controlados (iluminación, escala, rotación, entre otros) y en los entornos industriales no siempre se cuenta con la posibilidad de garantizar este tipo de condiciones. Esto genera que este tipo de enfoques sean limitados para la solución del problema [2–3]. Ejemplo de ello se evidencia con enfoques de caracterización por color, los cuales presentan fallas cuando se generan cambios de iluminación [4]. Por lo cual requieren de iluminación externa que evite estos cambios [9]. Otros enfoques proponen el uso morfológico de los patrones presentes en la escena, métodos que, a pesar de ser invariantes al cambio de color e iluminación, presentan dificultades cuando se generan oclusiones parciales causadas por factores externos como sombras u otros objetos [8].

Otro planteamiento, son los enfoques de textura los cuales se basan en transformaciones espacio-frecuencia. Estos cobran fuerza debido a que las telas producidas a partir de estos materiales presentan patrones periódicos que pueden ser ampliamente descritos en un espacio ortogonal [10 - 11], lo anterior permite robustez a las variaciones de color siendo potenciales para la implementación en ambientes no controlados de iluminación.

En otros trabajos se aborda el problema de control de calidad bajo un paradigma de diagnóstico, donde por medio de técnicas de visión por computador por caracterización de textura se identifica errores en un lote de producción, sin embargo, estos solo se concentran en la segmentación del área afectada, por lo tanto, el método sufre problemas con datos muy alejados a los valores de referencia [29-32].

Por otro lado existen métodos basados en técnicas de aprendizaje de máquina que buscan patrones de textura dado una imagen de entrada, si bien estos métodos logran agrupar un conjunto de píxeles a una respectiva textura, esto no puede ser denominado como un proceso de clasificación, sino un problema de segmentación, repitiendo el enfoque de los métodos anteriores, es decir, en la literatura se aborda tradicionalmente este problema de control de calidad como un paradigma de asignación de etiquetas sino bajo un enfoque comparación dado un patrón [33-40]. Otra estrategia busca por medio de un modelo de aprendizaje máquinas seleccionar productos textiles, sin embargo la documentación es limitada y los estudios realizados son exploratorios [28]. En este trabajo se propone aplicar técnicas de aprendizaje supervisado para clasificar productos textiles y caracterización espacio-frecuencia para la detección automática de tejidos terminados utilizando imágenes digitales. El método involucra la construcción de una base de datos anotada con diez tipos de telas. A este conjunto de datos se le extrae las características relevantes por medio de FFT- (Fast Fourier Transform), Wavelet y la Transformada corta en espacio de Fourier SSFFT (Short Space Fast Fourier Transform) [10 - 11]. Por medio de estos se evalúan tres métodos del estado del arte utilizados para clasificar datos, como son RNA, SVM y GP. Todo esto con el fin de determinar el desempeño de la metodología dado un cambio en el modelo de aprendizaje.

Este trabajo se organiza de la siguiente manera: Sección 1: Revisión del estado del arte en identificación de patrones en productos textiles, Sección 2: Materiales y Métodos, el cual consta de una etapa para la construcción de una base de datos anotada, una etapa de extracción de características y una etapa de entrenamiento y clasificación de métodos de aprendizaje de máquina. Sección 3: Análisis y Resultados, etapa que tiene como objetivo la validación de los métodos propuestos y la Sección 4: Conclusiones, la cual busca determinar el comportamiento de estos métodos para el problema específico de identificación de productos textiles.

1. ESTADO DEL ARTE

La industria textil es una de actividades que más genera ingresos a nivel mundial [29], pese a esto, también genera grandes pérdidas debido a los defectos de sus productos. Generalmente, la calidad de las telas producidas es evaluada por un inspector humano que, debido a factores como cansancio, falta de tiempo, errores propios, entre otros; califica como aprobados un gran porcentaje de productos que aún contienen imperfectos [30], la solución a este problema se ha planteado desde el área de reconocimiento de patrones y el procesamiento de imágenes digitales.

Los enfoques clásicos de reconocimiento patrones en imágenes digitales, utilizan una gran variedad de técnicas de caracterización, resaltándose como las más importantes el uso color, forma y textura. Las representaciones de color como los espacios RGB, CMYK, LAB, entre otros, permiten detectar patrones en una escena bajos las diferencias de color que cada objeto pueda tener en la escena, este tipo de enfoque son robustos frente a la deformación y oclusiones parciales. Pero al existir cambio de iluminación en la escena, los descriptores de color comienzan a

presentar inconvenientes debido a que son sensibles ante las variaciones fotométricas [11]. Otros enfoques clásicos como los descriptores SIFT, SURF, extraen las características morfológicas del objeto sin que las variaciones fotométricas de la escena afecten el rendimiento de estas técnicas. Aunque al presentarse cambios en la forma del objeto, se puede generar problemas en la clasificación, ya que estos descriptores no son aptos frente a oclusiones parciales o deformaciones del objeto [18].

Para clasificar los colores de la escena por clase, se utilizan métodos de aprendizaje de máquinas como redes neuronales artificiales multi-clase RNA, presentando aceptables rendimientos computacionales. Los métodos de agrupamiento presentan resultados satisfactorios siempre y cuando no se presenten dependencias entre las dimensiones de representación. Otros enfoques como las máquinas de soporte vectorial - SVM, clasificador bayesiano lineal, procesos Gaussianos, entre otros, ofrecen grandes ventajas para modelar grandes volúmenes de información, pero su costo computacional es alto [23 - 24].

Específicamente en trabajos de identificación automática de telas se han propuesto diversos métodos cuyo objetivo principal es encontrar defectos en las telas producidas, como son la segmentación de una imagen de alta definición del producto a inspeccionar para su posterior procesamiento mediante técnicas de color, filtros de media adaptativos y clasificación a través del uso de Redes Neuronales; obteniendo resultados cuyo porcentaje de acierto varía entre 70% y 93% [29, 41].

También, se han utilizado técnicas que buscan el análisis del producto mediante la observación de sus componentes de frecuencia [25-28] aunque los estudios acá presentados no pretenden ser exhaustivos. La transformada de Fourier, en su variación discreta (DFT) es planteada como herramienta de apoyo para un sistema autónomo de búsqueda y detección de defectos en productos, trabajando mediante la extracción de características a través de la cross-correlación para mejorar los resultados de la examinación de estructura frecuencial del material probado [30, 38,39, 26].

Métodos que combinan como factores como frecuencia estadística y espacial combinada de resolución múltiple, matriz de campo aleatorio de Markov, matrices de nivel de grises, co-ocurrencia entre otros; también han sido formulados como solución a la problemática de la detección de errores en productos textiles; obteniendo resultados de hasta el 96,6% por cada 25 muestras [31-35].

Metodologías basadas en Bandas Regulares, cuyo fin es analizar el patrón de textura mediante el cambio de la intensidad del píxel; filtrado con Wavelet de Gabor, realizando un análisis morfológico; análisis de textura con transformada Wavelet y redes neuronales LVQ, efectuando la evaluación de los materiales según técnicas de densidad Gaussiana y segmentación; y visión por computador y análisis digital de imágenes; también han sido utilizadas en la búsqueda de un desenlace a esta problemática, sin embargo, a pesar de que algunas de estas metodologías presenten resultados correctos hasta del 99,4%, otras tantas difícilmente alcanzan sobrepasan el umbral de 80% de acierto [32-36].

La combinación de sistemas adaptativos de deducciones borrosas basado en neuronas (ANFIS, por sus siglas en inglés) y transformadas Wavelet, han sido objeto de implementación, pero no han obtenido resultados mayores al 73% de acierto. Pese a esto, otra combinación puesta a prueba, la convergencia de redes neuronales y transformada Wavelet; sin embargo, sus resultados han sido similares a los primeros obtenidos [28, 33, 34].

También se presenta un estudio para la detección de textiles empleando las características espaciales de textura GLCM - (*Grey Level Co-Occurrence Matrix*), GLRLM (*Gray Level Difference Matrix*) y NGLDM (*Neighboring Gray Level Dependence Matrix*) y Máquinas de Soporte Vectorial. Aunque los resultados de este trabajo son porcentajes de acierto mayores al 80%, se considera que no es un porcentaje apto para considerar confiable la metodología, además de ser un número bajo de telas a detectar solo con cinco clases [24].

2. MATERIALES Y MÉTODOS

En esta sección, se enseña la estructura metodológica de trabajo, la cual se compone de tres procesos, en primer lugar, se tiene el conjunto de imágenes anotadas a clasificar (base de datos), en segundo lugar, una etapa la cual tiene como objetivo la extracción de características de cada imagen utilizando descriptores de espacio frecuencia y parámetros estadísticos, por último, una etapa de entrenamiento y validación que determina la clase de cada observación. En la figura 1, se enseña la metodología en diagrama de bloques.

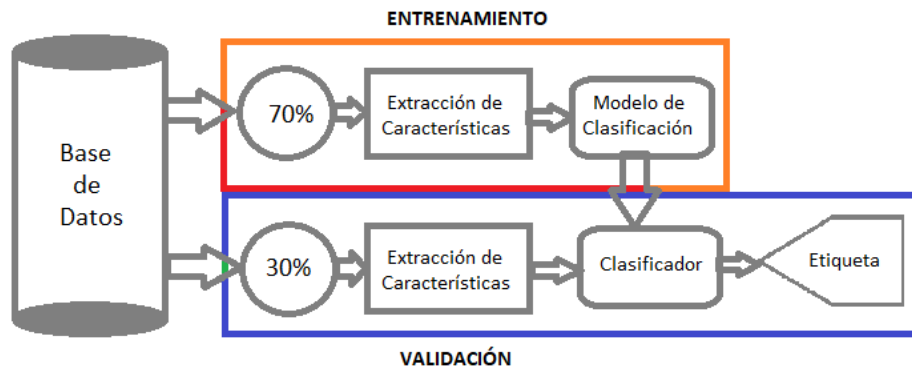


Figura 1. Metodología propuesta

2.1. Construcción base de datos

En el estado del arte existen diferentes bases de datos con imágenes de variación de texturas y productos textiles, tales como imágenes con arbustos, nubes, piedras, vidrios, arena, textiles, entre otras [41, 42]. Específicamente las bases de datos estándar para la inspección de productos textiles presentan el inconveniente de no estar disponibles, lo cual restringe la réplica y la comparación con trabajo similares. Por otro lado, éstas se utilizan para la identificación de errores en el producto

terminado, lo cual contrasta con el enfoque de este trabajo, el cual busca la selección automática del tejido [43].

Otra limitación reportada en trabajos del estado del arte, es el incumplimiento de las características de anotación requeridas y la cantidad de muestras necesarias por clase que debe tener la base de datos para asegurar validación estadística en los resultados. Además, las bases de datos comunes sólo consideran un solo tipo de tejido, lo anterior naturalmente restringe el comportamiento de la metodología para diferentes productos textiles. Por lo tanto, se realiza la construcción de una base de datos anotada que cumpla con estas características requeridas por este trabajo.

Para la captura de las imágenes, se utilizó un *smartphone* con cámara digital de resolución de 1080 x 1920, la base de datos se conforma de diez telas comunes con diferentes patrones en el cocido. Lo anterior con el propósito de observar el aporte de cada descriptor. Para cada clase de tela se capturaron 100 imágenes obteniendo un total de 1000 fotografías y se resalta que estas capturas se realizaron en diferentes momentos y sin un entorno controlado de iluminación, además no se asume calibración de la cámara. En la figura 2 se resume las diferentes clases de telas.



Figura 2. Tipos de telas de la base de datos construida.

2.2. Extracción de características

Este proceso inicia transformando cada imagen de la base de datos a escala de grises, debido a que un análisis de textura el color es irrelevante. Luego esta es transportada a un dominio de frecuencia. Para ello se utiliza la Transformada Rápida de Fourier en dos dimensiones (FFT), la transformada discreta de Wavelet en dos dimensiones (DWT) y un método propuesto el cual se denomina Adaptación de la Transformada corta en tiempo de Fourier para imágenes (SSFT), el cual se propone

y se evalúa de forma exploratoria. Nótese que la metodología inicia computando un conjunto de coeficientes que describen la imagen real en el dominio de la frecuencia, para cada uno de los descriptores que hacen parte del análisis. En la tabla 1 se enseña la nomenclatura a utilizar para descripción de extracción de características [13].

Tabla 1: Nomenclatura extracción de características

u	Coordenada espacial de la fila en el espacio de la frecuencia
v	coordenada espacial de columna en el dominio de Fourier
nc	número de filas de la imagen
nf	número de columnas de la imagen
$I(c, f)$	imagen en escalas de grises en la posición
j_0	Escala inicial arbitraria
$DWT_{\psi}(j, m, n)$	Coefficientes que definen los detalles horizontales, verticales y diagonales
Ω	Conjunto de características
$F(u, v)$	Coefficiente transformada de Fourier
$\frac{\sum_{i=0}^{N-1} F_i(u, v)}{N} = \bar{F}(u, v)$	Media aritmética
$\sqrt{\frac{\sum_{i=0}^{N-1} (F_i(u, v) - \bar{F}(u, v))^2}{N}} = \sigma$	Desviación Estándar
$\frac{\sum_{i=0}^{N-1} (F_i(u, v) - \bar{F}(u, v))^4}{N\sigma^4}$	Kurtosis
$\frac{\sum_{i=0}^{N-1} (F_i(u, v) - \bar{F}(u, v))^3}{N\sigma^3}$	Sesgo

Es de aclarar que el cálculo de parámetros estadísticos es aplicable de igual manera a los coeficientes DWT_{ψ} . Para el análisis acá presentado se ignora la componente imaginaria de las transformaciones.




Figura 3. Partición de la imagen en ventanas.

Las transformaciones permiten calcular el espectro y las variaciones de frecuencia de la imagen en escala de grises, las cuales vienen dadas por un vector de coeficientes $F(u, v)$ y DWT_{ψ} . Luego a partir de este se procede a encontrar los parámetros estadísticos de la transformación, esto son media, desviación estándar, sesgo y *Kurtosis* [12]. De esta forma por cada imagen, la metodología computa un conjunto de características Ω de dimensiones 4×1 para los descriptores FFT y DWT.

Para el cálculo del descriptor SSFT se procede inicialmente con recortar la fotografía en ventanas cuadradas iguales, tal como se enseña en la figura 3. Luego se aplica la transformación $F(u, v)$ en cada uno de los recortes, obteniendo un vector de coeficientes en el dominio de la frecuencia, al final se calcula el vector de parámetros estadísticos, el cual tiene dimensión $4L \times 1$ donde L es el número de ventanas cuadradas de la imagen.

2.3. Entrenamiento y Clasificación

En esta etapa las características entregadas por los diferentes descriptores y sus respectivas etiquetas son entregadas al clasificador, el 70% de los datos son utilizados para el entrenamiento, el restante para validación, fraccionados aleatoriamente por medio de una distribución Gaussiana. La validación se realiza por medio de un experimento de MonteCarlo, para cuantificar el desempeño del clasificador. Para este trabajo se hace utilizaron tres métodos de entrenamiento supervisado. Una Red Neuronal Multicapa (ANN), una Máquina de Soporte Vectorial (SVM) y un Proceso Gaussiano (GP), como modelos de aprendizaje.

Teniendo en cuenta que las SVM son un método de clasificación binario, se implementa la estrategia de clasificación multi-clase Uno vs Todos. Este método cuenta con el algoritmo de optimización mínima secuencial (OMS) para el entrenamiento del modelo [22]. Para realizar un análisis de separabilidad del espacio de características se propone el uso de tres *Kernels* (Lineal, Polinomial y Gaussiano con radio adaptativo). Para lograr la implementación de este algoritmo se utiliza la función *Fitcecoc* de Matlab®. Para la clasificación con el método binario GP, se implementa una estrategia uno vs todos [22]. Al igual que el método anterior, se propone el uso de dos *Kernels* (Gaussiano y Exponencial cuadrado). Para lograr la implementación se utiliza el *toolbox* GPML Matlab® versión 4.1 utilizando como método de inferencia una regresión con probabilidad Gaussiana [26], Para la ANN se utiliza el algoritmo *Backpropagation* con dos capas ocultas y 20 neuronas por capa, la selección de parámetros se realiza con la heurística del mejor desempeño.

Finalmente, el criterio de convergencia del algoritmo de Montecarlo, es el cálculo de similaridad provisto por la distancia $diag(k)-diag(k-1) < 0.001$, donde $diag(k)$ es el vector generado por la diagonal de la matriz de confusión y k es el valor de iteración actual. Las estadísticas obtenidas en el experimento consisten en el cálculo de la matriz de confusión y el comportamiento promedio de la tasa de éxito y su desviación estándar.

Con el objetivo de realizar comparaciones metodológicas y cuantificar el aporte de este trabajo, se propone aplicar variaciones a los modelos de aprendizaje de máquinas incluyendo el uso de *Kernels* Lineales, Gaussianos y Polinomiales. Además de comparar un instrumento de caracterización de textura del estado del arte como lo es SFTA (*Segmentation-based Fractal Texture Analysis*) [27].

3. ANALISIS Y RESULTADOS

Debido a la cantidad de experimentos realizados, solo se documentan las diagonales de la matriz de confusión correspondientes al porcentaje de acierto de cada clase. En las tablas 2, 3 y 4 se enseñan los resultados de identificación para el caso de las SVM el GP en un experimento de Montecarlo variando la función de covarianza y el tipo de descriptor. En estas se presenta el desempeño de acierto promedio, que consiste en calcular el valor medio del vector de etiquetas de resultante de la matriz de confusión, tal y como se puede observar al final de las tablas 2,3 y 4.

Tabla 2. Diagonal principal de las matrices de confusión de todos los métodos FFT Y SSFT implementados utilizando SVM.

Clase	FFT-SVM			SSFT-SVM		
	Lineal	Polinomial orden 4	RBF con radio adaptivo	Lineal	Polinomial orden 4	RBF con radio adaptivo
C1	96.89±3.4	96.39±1.86	96.77±0.0	100.00±0	98.39±2.28	100.00±0.0
C2	99.83±0.74	100.00±0.0	100.00±0.0	100.00±0	100.00±0.0	100.00±0.0
C3	76.36±5.6	100.00±0.0	100.00±0.0	100.00±0	100.00±0.0	100.00±0.0
C4	83.54±10.3	100.00±0.0	100.00±0.0	100.00±0	100.00±0.0	100.00±0.0
C5	83.54±10.4	100.00±0.0	100.00±0.0	100.00±0	100.00±0.0	100.00±0.0
C6	99.46±6.24	100.00±0.0	100.00±0.0	100.00±0	100.00±0.0	100.00±0.0
C7	95.5±6.73	98.44±3.12	100.00±0.0	100.00±0	100.00±0.0	100.00±0.0
C8	89.29±7.66	100.00±0.0	100.00±0.0	100.00±0	100.00±0.0	100.00±0.0
C9	100.00±0.0	100.00±0.0	100.00±0.0	100.00±0	100.00±0.0	100.00±0.0
C10	98.95±1.97	100.00±0.0	100.00±0.0	100.00±0	96.88±4.42	100.00±0.0
Total	92.34±8.55	99.48±1.19	99.67±1.02	100.00±0	99.52±1.05	100.00±0.0

En las tablas 2 y 3 se evidencia el resultado de los experimentos de Montecarlo utilizando el enfoque de máquinas de soporte vectorial (SVM). Se puede evidenciar que para este conjunto de experimentos se utilizan tres *kernels* (Lineal, Polinomial y Gaussiano Radial -RBF) y se computan los desempeños de acierto promedio. De las tablas 2 y 3 se puede observar un alto rendimiento para la detección de las diferentes telas, con porcentajes de acierto mayores al 75% para los diferentes experimentos propuestos. Se exceptúan de este análisis el *kernel* lineal con Wavelet y el Kernel lineal con SFTA donde se obtuvo los peores desempeños (46.15±10.88 %, 44.73±1.34%). Se puede observar que en general la utilización de un *kernel* RBF con radio adaptativo permite en la separación de los datos obtener los mayores rendimientos (FFT=99.67±1.02%, SSFT=100.00±0.0% y Wavelet=91.81±9.36%). También se percibe que el *kernel* lineal evidencia los desempeños más bajos (FFT=92.34±8.55% y Wavelet=81.75±15.92%), sin embargo, se resalta que este enfoque presenta un rendimiento del 100% utilizando la SSFT. El método Wavelet presenta porcentajes de acierto confiables 90%, sin embargo, se observa que las clases 4,6,8 y 10 presentan bajos rendimientos menores al 85%, lo cual sugiere que la metodología no da garantía para detectar este tipo de patrones. Los resultados sugieren que el descriptor SFTA con SVM no es un candidato apto para la identificación de texturas, ya que no permite extraer

características relevantes que permita al clasificador computar un plano de separación para cada una de las clases, esto se puede observar en la tabla 3 donde la clase 3 presenta desempeños del 0%.

Tabla 3. Diagonal principal de las matrices de confusión de todos los métodos Wavelet Y SFTA implementados utilizando SVM.

Clase	Wavelet-SVM			SFTA-SVM		
	Lineal	Polinomial orden 4	RBF con radio adaptivo	Lineal	Polinomial orden 4	RBF con radio adaptivo
C1	96.55±0.17	95.31±6.63	96.81±4.1	44.68±0.78	43.21±2.34	44.73±1.34
C2	95.11±2.2	91.13±7.66	95.15±2.4	100.00±0.0	100.00±0.0	100.00±0.0
C3	75.59±15.6 6	79.93±12.6 7	90.80±5.1	100.00±0.0	100.00±0.0	100.00±0.0
C4	83.15±14.4	98±2.83	74.91±7.0	100.00±0.0	100.00±0.0	100.00±0.0
C5	100.00±0.0	95.15±1.98	100.00±0.0	100.00±0.0	100.00±0.0	100.00±0.0
C6	83.33±0.01	100.00±0.0	100.00±0.0	0.0±0.0	0.0±0.0	0.0±0.0
C7	68.43±8.39	98.39±2.28	96.63±2.5	100.00±0.0	100.00±0.0	100.00±0.0
C8	76.73±1.49	79.66±4.52	75.60±5.5	100.00±0.0	100.00±0.0	100.00±0.0
C9	89.48±3.57	100.00±0.0	98.36±2.4	100.00±0.0	100.00±0.0	100.00±0.0
C10	46.15±10.8 8	85.69±2.57	89.87±5.7	100.00±0.0	100.00±0.0	100.00±0.0
Total	81.75±15.9 2	92.32±7.91	91.81±9.36	84.46±34.39	84.32±34.58	84.5±34.38

Para el caso del GP al igual que en las SVM, se propone el uso de *kernels* para la mejora en la separación de los datos. De este se resalta que al hacer pruebas con los *kernels* lineal y polinomial los desempeños de clasificación fueron no confiables con aciertos menores al 50% concluyendo que para este tipo de clasificador no garantizan una correcta separación y por el contrario traslapan el espacio de entrenamiento. Por lo tanto, sólo se documentan los resultados obtenidos con el *kernels* Exponencial cuadrado con radio adaptativo y Gaussiano Radial -RBF.

De la tabla 4 se aprecia que el GP genera un alto rendimiento para la detección estos patrones, con porcentajes de acierto mayores al 90% para los diferentes experimentos propuestos. Se exceptúan de este resultado el método de

caracterización SSFT con *kernel* Exponencial cuadrado con un porcentaje de acierto del 17.44 ± 2.33 % para la clase 1 y el método Wavelet con *kernel* RBF con bajo desempeño para la mayoría de sus clases. Al igual que en los experimentos con SVM, se puede observar que el uso de un *kernel* RBF mejora la separación de los datos obteniendo los mejores desempeños (FFT=100%, SSFT=100.00%), sin embargo, se observa que en la metodología Wavelet el desempeño $78.48 \pm 18.32\%$, porcentaje bajo para garantizar confiabilidad del método. Esto ayuda a reforzar al igual que en los experimentos anteriores que el método caracterización con transformada Wavelet no es adecuado para garantizar una correcta clasificación de los datos. Por razones similares no se reporta la combinación del método SFTA con GP.

Tabla 4. Diagonal principal de las matrices de confusión de todos los métodos utilizando GP

Clase	FFT-GP		SSFT-GP		Wavelet-GP	
	Exponencial cuadrado con radio adaptativo	RBF con radio adaptativo	Exponencial cuadrado con radio adaptativo	RBF con radio adaptativo	Exponencial cuadrado con radio adaptativo	RBF con radio adaptativo
C1	100.00±0	100.00±0	17.44±2.3	100.00±0.0	96.62±5.67	96.77±4.3
C2	100.00±0	100.00±0	100.00±0	100.00±0.0	94.53±6.71	88.24±9.3
C3	100.00±0	100.00±0	100.00±0	100.00±0.0	97.32±3.38	47.87±14.9
C4	100.00±0	100.00±0	100.00±0	100.00±0.0	98.84±2.82	70.57±6.63
C5	100.00±0	100.00±0	100.00±0	100.00±0.0	98.94±2.07	93.55±4.65
C6	100.00±0	100.00±0	100.00±0	100.00±0.0	95.67±4.59	75.0±10.32
C7	100.00±0	100.00±0	100.00±0	100.00±0.0	98.64±2.55	100.00±0.0
C8	100.00±0	100.00±0	100.00±0	100.00±0.0	96.27±3.29	70.0±13.51
C9	100.00±0	100.00±0	100.00±0	100.00±0.0	97.68±2.11	50.00±10.83
C10	100.00±0	100.00±0	100.00±0	100.00±0.0	94.68±4.18	82.76±7.47
Total	100.00±0	100.00±0	91.74±26.1	100.00±0.0	96.95±1.61	77.48±18.32

En la tabla 5 se enseña la comparación entre los diferentes descriptores utilizados con el clasificador RNA, obteniendo un desempeño disperso comparado con las SVM y el GP. Esto se puede apreciar en Wavelet-RNA en las clases cuatro y ocho que presentan un porcentaje de acierto menor al 80% y se evidencia que el mejor desempeño lo tiene la SSFT-RNA. De la tabla 5 se evidencia que los métodos con

mejor desempeño son los que utilizan el descriptor SSFT, logrando un desempeño ideal del 100% para la base de datos propuesta, aunque estos desempeños son ideales, se evidencia los métodos de caracterización que utilizan la FFT presenta desempeños similares del 99%, por lo tanto, se puede evidenciar que el método es confiable. También se evidencia que la transformada Wavelet tiene un desempeño mayor al 90%, sin embargo la desviación estándar es grande, lo cual evidencia que el método presenta problemas para ser utilizado como descriptor de textura en este tipo de telas, tal y como se evidencia en los otros métodos de clasificación. Por otro lado, el método de caracterización STFA brinda un espacio separación adecuado para clasificar con RNA, esto se evidencia al obtener un desempeño promedio de $99.24 \pm 1.01\%$. Cabe resaltar que este descriptor con un clasificador SVM no presentó un desempeño adecuado, por lo que este clasificador muestra dependencia del método de aprendizaje escogido.

Tabla 5. Diagonal principal de las matrices de confusión de todos los métodos utilizando RNA

Clases	FFT-RNA	SSFT-RNA	Wavelet-RNA	STFA-RNA
C1	99.88±0.7	100.00±0.0	96.81±4.1	100.00±0.0
C2	99.39±1.3	100.00±0.0	95.15±2.4	96.87±17.68
C3	100.00±0.0	100.00±0.0	90.80±5.1	100.00±0.0
C4	99.72±1.6	100.00±0.0	74.91±7.0	99.31±1.98
C5	100.00±0.0	100.00±0.0	100.00±0.0	100.00±0.0
C6	99.05±1.5	100.00±0.0	100.00±0.0	100.00±0.0
C7	100.00±0.0	100.0±0.0	96.63±2.5	98.80±0.79
C8	97.25±8.0	100.0±0.0	75.60±5.5	99.83±0.98
C9	100.00±0.0	100.00±0.0	98.36±2.4	100.00±0.0
C10	100.00±0.0	100.00±0.0	89.87±5.7	98.68±7.48
Total	99.52±0.86	100.00±0.0	91.81±9.36	99.24±1.01

Al comparar los desempeños de las diferentes metodologías se observan que el descriptor SSFT corresponde al de los mejores desempeños con porcentajes de acierto del 100%, esto evidencia que la caracterización local de frecuencias es adecuada para caracterización de patrones en productos textiles. También es importante resalta que la FFT evidencia resultados de acierto confiables del 99% lo que permite concluir que un método estadísticamente similar a la SSFT.

A continuación, se procede a realizar un estudio de costo computacional de cada una de las variantes que hacen parte del análisis. Para ello se cuantifica la cantidad de tiempo requerido para computar cada descriptor y una iteración de Montecarlo utilizando SVM, GP y RNA ver tabla 6, 7 y 8, cabe resaltar que estos experimentos se llevaron a cabo en un computador con 16GB de RAM y un procesador Core i7.

Tabla 6. Comparación de tiempos para la extracción de características.

	Descriptor			
	FFT	SSFT	Wavelet	SFTA
Tiempo (s)	0.28±0.03	0.49±0.03	0.23±0.02	7.23±1.4

La tabla 7 muestra que el método de caracterización con transformada FFT presenta el menor costo computacional al obtener tiempos de ejecución de $0,23\pm 0,11$ [s]. Por otro lado el descriptor SSFT requiere de un costo computacional mayor. Esto se debe a que el método SSFT aumenta considerablemente el número de dimensiones de características. Aunque este consume una cantidad de recursos considerable, es importante resaltar que cuando se utiliza un *kernel* lineal este tiempo es relativamente bajo ($0,92\pm 0,21$).

Tabla 7. Tiempo de iteración Montecarlo utilizando SVM

	FFT			SSFT		
	Lineal	Polinomial orden 4	RBF con radio adaptivo	Lineal	Polinomial orden 4	RBF con radio adaptivo
Tiempo (S)	0,87±0.37	105,1±8.86	0,23±0,11	0,92±0.21	105,1±8.86	1,12±0,42
	Wavelet			SFTA		
	Lineal	Polinomial orden 4	RBF con radio adaptivo	Lineal	Polinomial orden 4	RBF con radio adaptivo
Tiempo (S)	0,69±0.46	12,98±8.83	0,76±0,27	6,87±0.37	605,1±8.86	6,23±0,11

En la tabla 8 se observa el tiempo de cómputo en los experimentos de Montecarlo con el método de clasificación GP. Aunque esta variante presenta resultados confiables en su desempeño los recursos que requiere para ejecución son elevados comparados con los requeridos por la SVM.

Tabla 8. Tiempo de iteración Montecarlo utilizando GP

	FFT		SSFT		Wavelet	
	Exponencial cuadrado con radio adaptativo	RBF con radio adaptivo	Exponencial cuadrado con radio adaptativo	RBF con radio adaptivo	Exponencial cuadrado con radio adaptativo	RBF con radio adaptivo
Tiempo (S)	222.96±12.8	228.15±13.1	373.15±27.31	381.56±34.2	239.97±13.3	252.82±16.2

Tabla 9. Tiempo de iteración Montecarlo utilizando RNA.

	RNA			
	FFT	SSFT	Wavelet	SFTA
Tiempo (s)	2,19±0,64	683±111,12	10,04±2,72	40,04±2,72

Para las RNA se observa un comportamiento similar al obtenido por la SVM respecto a comparación entre descriptores, también cabe resaltar que en general la SVM presento menores tiempo de computo que la RNA ver tabla 9..

4. CONCLUSIONES

Se realizó un estudio detallado de la caracterización espacio frecuencia para la identificación de patrones de textura utilizando métodos clásicos de aprendizaje supervisado como como SVM, GP y RNA. Este enfoque permite utilizar los patrones espaciales de textura de una imagen digital y ser caracterizados por medio transformadas como FFT, SSFT y Wavelet, obteniendo un espacio de representación que cuantifica las variaciones de frecuencia y son descriptos por momentos estadísticos, la media, la desviación estándar, el sesgo y la Kurtosis. Por medio de estos procesos se logra resultados confiables mayores al 90% de eficiencia para una base de datos anotada de 10 telas diferentes. En este trabajo se logra cuantificar el rendimiento de algunos métodos de aprendizaje máquinas supervisado, comunes en la literatura (SVM, RNA y GP) para un problema de selección de productos textiles, lo anterior es muy importante debido a la limitada documentación presente en la literatura que aborda el problema de inspección de textiles bajo un paradigma de clasificación.

Basados en los resultados se logra identificar que el éxito se asocia al *Kernel* utilizando. Esto implica que la elección del este permite mejorar la eficiencia en la identificación del patrón. Se resalta que la representación con un *kernel* lineal genera bajos rendimientos tal y como se observa en las tablas 2, 3 y 4. Sin embargo para el caso de clasificación SVM generan resultado de alta confiabilidad.

Los métodos de SSFT-SVM, SSFT-GP y SSFT-RNA lograron un desempeño del 100% demostrando ser una metodología adecuada para este tipo de aplicaciones.

Sin embargo, se debe tener en cuenta el alto costo computacional asociado a la alta dimensión del descriptor.

En la transformada Wavelet con SVM y RNA, el desempeño es mayor al 90%, sin embargo, la incertidumbre es alta, lo cual sugiere un rango que no es aceptable para considerar este descriptor en una aplicación real. Esta observación también se puede apoyar en los diferentes *Kernels*, donde ninguno de los experimentos que realizó con este tipo de descriptor, logró que todas las clases tuvieran porcentaje de acierto mayores al 90% tal y como se observa en las tablas 2, 3, 4 y 5.

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 significativamente menor respecto a los demás descriptores, por lo tanto, se puede considerar que este es un candidato para ser implementado, debido a que estadísticamente presenta un funcionamiento similar al del mejor rendimiento (SSFT), con un costo de cómputo razonable.

Por otro lado, se puede observar que el método de caracterización SFTA brinda un espacio separación adecuado para identificar productos textiles utilizando RNA, lo cual se evidenció al obtener un desempeño promedio de $99.24 \pm 1.01\%$. Por esta razón este descriptor no debe ser descartado para la caracterización de este tipo de texturas, aunque con otros tipos de clasificadores su desempeño sea bajo (SVM y GP).

AGRADECIMIENTO

Un agradecimiento al Centro Atención Sector Agropecuario – SENA, a Tecnoparque nodo Pereira línea de Electrónica y Telecomunicaciones y a la Universidad Tecnológica de Pereira por el apoyo recibido durante el desarrollo del presente trabajo.

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. <https://doi.org/10.1109/IST.2010.5548466>
- [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. <https://doi.org/10.1109/INMIC.2008.4777721>
- [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. <https://doi.org/10.1109/AVSS.2011.6027383>

- [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
- [7] COATS, "Todo Sobre Fibras Textiles". [En línea]. Disponible en: http://www.coatsindustrial.com/es/images/Know_About_Textile_Fibres_tcm62-9073.pdf
- [8] Dengsheng Zhang and Guojun Lu, "Generic Fourier descriptor for shape-based image retrieval," Proceedings. IEEE International Conference on Multimedia and Expo, 2002, pp. 425-428 vol.1. <https://doi.org/10.1109/ICME.2002.1035809>
- [9] Yining Deng, B. S. Manjunath, C. Kenney, M. S. Moore and H. Shin, "An efficient color representation for image retrieval," in IEEE Transactions on Image Processing, vol. 10, no. 1, pp. 140-147, Jan 2001. <https://doi.org/10.1109/83.892450>
- [10] Ashok Veeraraghavan, Ramesh Raskar, Amit Agrawal, Ankit Mohan, and Jack Tumblin. 2007. Dappled photography: mask enhanced cameras for heterodyned light fields and coded aperture refocusing. ACM Trans. Graph. 26, 3, Article 69 (July 2007). <https://doi.org/10.1145/1276377.1276463>
- [11] PERNER-NOCHTA, Iris; POSTEN, Clemens. Simulations of light intensity variation in photobioreactors. Journal of Biotechnology, 2007, vol. 131, no 3, p. 276-285. <https://doi.org/10.1016/j.jbiotec.2007.05.024>
- [13] S. G. Mallat, "A theory for multiresolution signal decomposition: the wavelet representation," in IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 11, no. 7, pp. 674-693, Jul 1989. <https://doi.org/10.1109/34.192463>
- [14] Meyer, Y. Ondelettes et opérateurs, Tome 1, Hermann Ed. (English translation: Wavelets and operators, Cambridge Univ. Press. 1993.)
- [15] J. Núñez, J.C. Carvajal, L.A. Bautista, "El TLC con estados unidos y su impacto en el sector agropecuario colombiano: Entre esperanzas e incertidumbres", Revista Electrónica de la facultad de Derecho, 1 (1), 118-133, 2004.
- [16] V.A. Contreras, C. Gutiérrez, M.E. León, Y. Cadena, F.E. León, "Iso 9001-2: un compromiso posible en la era del TLC," Revista Teoría Y Praxis Investigativa, 3 (2), 52-60, 2008.
- [17] A. Bejarano & A. F. Calvo, (2012) Escáner 3d para control de calidad de piezas metalúrgicas. Tesis de pre-grado, Universidad Tecnológica de Pereira.
- [18] N. Florez, L.P. Sánchez, F.G. Ramírez, (2011) Visión Artificial Para Detección Automática de Fallas Estructurales en Botellas de Vidrio. Tesis de Maestría, Instituto politécnico nacional.

- [19] J.M. Prats, (2005) Control Estadístico de Procesos Mediante Análisis Multivariante de Imágenes. Tesis de Doctorado, Universidad Politécnica de Valencia.
- [20] 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. <https://doi.org/10.1109/IST.2010.5548466>
- [21] C. G. Spinola, J. Canero, G. Moreno-Aranda, J. M. Bonelo and M. Martin-Vazquez, "Real-time image processing for edge inspection and defect detection in stainless steel production lines," 2011 IEEE International Conference on Imaging Systems and Techniques, Penang, 2011, pp. 170-175. <https://doi.org/10.1109/IST.2011.5962196>
- [22] A. Bejarano Martínez, A. F. Calvo and C. A. Henao, "Supervised learning models for control quality by using color descriptors: A study case," 2016 XXI Symposium on Signal Processing, Images and Artificial Vision (STSIVA), Bucaramanga, 2016, pp. 1-7. <https://doi.org/10.1109/STSIVA.2016.7743368>
- [23] B. S. Shedthi, S. Shetty and M. Siddappa, "Implementation and comparison of K-means and fuzzy C-means algorithms for agricultural data," 2017 International Conference on Inventive Communication and Computational Technologies (ICICCT), Coimbatore, 2017, pp. 105-108. <https://doi.org/10.1109/ICICCT.2017.7975168>
- [24] Duber Martínez Torres y Sergio Orjuela. Máquina de Vectores de soporte para la detección de defectos textiles empleando características espaciales de textura. Revista Colombiana de Tecnologías de Avanzada. ISSN: 1692-7257, Vol 2, No 14, 2009
- [25] Chi-Ho Chan and G. Pang, "Fabric defect detection by Fourier analysis," Conference Record of the 1999 IEEE Industry Applications Conference. Thirty-Forth IAS Annual Meeting (Cat. No.99CH36370), Phoenix, AZ, 1999, pp. 1743-1750 vol.3. <https://doi.org/10.1109/IAS.1999.805975>
- [26] Sungshin Kim, Man Hung Lee and Kwang-Bang Woo, "Wavelet analysis to fabric defects detection in weaving processes," Industrial Electronics, 1999. ISIE '99. Proceedings of the IEEE International Symposium on, Bled, 1999, pp. 1406-1409 vol.3. <https://doi.org/10.1109/ISIE.1999.796918>
- [27] A. F. Costa, G. Humpire-Mamani and A. J. M. Traina, "An Efficient Algorithm for Fractal Analysis of Textures," 2012 25th SIBGRAPI Conference on Graphics, Patterns and Images, Ouro Preto, 2012, pp. 39-46. <https://doi.org/10.1109/SIBGRAPI.2012.15>
- [28] A. Bejarano Martínez, A. F. Calvo and C. A. Henao "Identificación automática de productos textiles utilizando caracterización espacio frecuencia y aprendizaje supervisado". Congreso Internacional de Multimedia 2017.
- [29] Nasira, G. M., & Banumathi, P. (2014). Automatic defect detection algorithm for woven fabric using artificial neural network techniques. International Journal of Innovative Research in Computer and Communication Engineering, 2(1). ISSN: 2320-9801

- [30] Nasira, G. M., & Banumathi, P. (2013). Fourier transform and image processing in automated fabric defect inspection system. *Int J Comput Int Info*, 3(1), 61-64. ISSN: 2349 - 6363
- [31] Sabeenian, R. S., Paramasivam, M. E., & Dinesh, P. M. (2012). Computer vision based defect detection and identification in handloom silk fabrics. *Computer*, 42(17).
- [32] Javed, A., & Mirza, A. U. (2013). Comparative analysis of different fabric defects detection techniques. *International Journal of Image, Graphics and Signal Processing*, 5(1), 40. <https://doi.org/10.5815/ijigsp.2013.01.06>
- [33] B. Venkatesan, U. S. Ragupathy, P. Vidhyalakshmi and B. Vinoth, "Inspection of faults in textile web materials using wavelets and ANFIS," 2012 International Conference on Machine Vision and Image Processing (MVIP), Taipei, 2012, pp. 189-192. <https://doi.org/10.1109/MVIP.2012.6428792>
- [34] Z. Kang, C. Yuan and Q. Yang, "The fabric defect detection technology based on wavelet transform and neural network convergence," 2013 IEEE International Conference on Information and Automation (ICIA), Yinchuan, 2013, pp. 597-601. <https://doi.org/10.1109/ICInfA.2013.6720367>
- [35] Clausi, D. A. (2002). An analysis of co-occurrence texture statistics as a function of grey level quantization. *Canadian Journal of remote sensing*, 28(1), 45-62. <https://doi.org/10.1109/TMI.2012.2206398>
- [36] X. Wang, N. D. Georganas and E. M. Petriu, "Fabric Texture Analysis Using Computer Vision Techniques," in *IEEE Transactions on Instrumentation and Measurement*, vol. 60, no. 1, pp. 44-56, Jan. 2011. <https://doi.org/10.1109/TIM.2010.2069850>
- [37] Moussa, A., Dupont, D., Steen, D., & Zeng, X. (2010). Structure analysis and surface simulation of woven fabrics using fast Fourier transform techniques. *The Journal of The Textile Institute*, 101(6), 556-570. <https://doi.org/10.1080/00405000802596958>
- [38] Jayashree, V., & Subbaraman, S. (2012). Identification of twill grey fabric defects using DC suppressed Fourier power spectrum sum features. *Textile Research Journal*, 82(14), 1485-1497. <https://doi.org/10.1177/0040517511404593>
- [39] Habib, Md & Rokonzaman, M. (2011). Distinguishing Feature Selection for Fabric Defect Classification Using Neural Network. *Journal of Multimedia*. 6. 416-424. <https://doi.org/10.1109/ICCITECHN.2010.5723905>
- [40] Hui, C. L. P., Fun, N. S., & Ip, C. (2011). Review of application of artificial neural networks in textiles and clothing industries over last decades. In *Artificial Neural Networks-Industrial and Control Engineering Applications*. InTech. <https://doi.org/10.5772/2052>
- [41] A. Kumar, "Computer-Vision-Based Fabric Defect Detection: A Survey," in *IEEE Transactions on Industrial Electronics*, vol. 55, no. 1, pp. 348-363, Jan. 2008. <https://doi.org/10.1109/TIE.1930.896476>

[42] P. Brodatz, Textures: A Photographic Album for Artists and Designers, Dover, New York, (1966).

[43] Workgroup on Texture Analysis of DFG, TILDA Textile Texture Database,

ARTICULO ACEPTADO