

**PROPOSAL OF A NEW KERNEL METHOD LAWS-BASED FOR SURFACE
ROUGHNESS EVALUATION****PROPUESTA DE UN NUEVO MÉTODO KERNEL BASADO EN LAWS PARA
EVALUAR LA RUGOSIDAD DE PIEZAS METÁLICAS**

PhD. Sir Alexci Suarez*, PhD(c). Maribel González Rodríguez
PhD. Albert Miyer Suárez*****

*** Universidad Simón Bolívar**

Av. 3, No. 13-34, La Playa, Cúcuta, Colombia.

E-mail: [sasuuac@unileon.es](mailto:sasuac@unileon.es)

**** Universidad de León**

Campus de Vegazana S/N, 24071, León, España,

Tel.: 34-627319569, Fax 34-987291790, E-mail: maribel.gonzalez@unileon.es

***** Universidad de Pamplona**

Ciudadela Universitaria. Pamplona, Norte de Santander, Colombia.

Tel.: (577)-568 5303 Ext. 164, Fax: (577)-568 5303, Ext. 154.

E-mail: asuarez@unipamplona.edu.co

Abstract: A new descriptor based in Laws is proposed in this paper that allows classifying turned metallic parts as function of their superficial roughness. The material used for the tests was the AISI 6150 steel, considered one of the reference steels in the market. The proposed solution is based on a vision system which calculates the actual roughness using as fundament the analysis of texture on the part images. The kernel developed to quantify the roughness is based on the R5R5 mask presented by Laws. The results of combining the proposed R5SR5S kernel with the standard diversion allows to classify the images with a rate of success of 95,87% using Linear Discriminant Analysis, and 97,3% using Quadratic Discriminant Analysis. These results demonstrate that the proposed technique can be effectively used to evaluate the roughness in machining processes.

Keywords: Roughness, Laws, co-occurrence matrix, surface texture.

Resumen: En este artículo se propone un nuevo descriptor basado en Laws, que permite clasificar piezas metálicas que han sido mecanizadas mediante operaciones de torneado evaluando la rugosidad superficial. La solución se basa en un sistema de visión el cual analiza la rugosidad presente en las imágenes a partir de la textura. Se han realizado operaciones de torneado utilizando la aleación AISI 6150. El kernel desarrollado para cuantificar la rugosidad se basa en el R5R5 presentado por Laws. Los resultados del kernel propuesto combinado con la desviación estándar permite clasificar las imágenes con una tasa de acierto de 95.87% con LDA y 97.3% con QDA, demostrando que puede ser utilizado para evaluar la rugosidad en procesos de mecanizado.

Palabras clave: Rugosidad, Laws, Matriz de co-ocurrencia, textura superficial.

1. INTRODUCCIÓN

Los defectos que se presentan en las piezas metálicas después de un proceso de mecanizado, pueden determinar la calidad y tiempo de vida de un dispositivo o máquina al cual se integran. Estos defectos son difíciles de detectar, por eso uno de los aspectos más importantes en los sistemas de control de calidad es detectar las piezas defectuosas de forma precisa y en el menor tiempo posible, permitiendo una reducción de costos de fabricación y entrega de productos.

Uno de los factores que permiten definir el estado superficial de las piezas es la evaluación del valor de la rugosidad, la cual permite detectar irregularidades en la superficie. Para medir la rugosidad existen diversos parámetros que permiten evaluar la superficie y precisar si el valor se encuentra en el rango permitido por normas internacionales o los criterios específicos del producto. Este proceso de inspección, evaluación y clasificación es ejecutado en un porcentaje elevado con sistemas tradicionales, originando que muchas piezas defectuosas no sean detectadas. Normalmente esta tarea se puede realizar de dos maneras: 1) el primero es automatizado, y consiste en obtener el valor de la rugosidad mediante un rugosímetro en la misma línea de fabricación, causando que el proceso sea lento e inclusive deba detenerse, y 2) agrupando las piezas para ser medidas después con ayuda de operarios. Teniendo en cuenta estos inconvenientes, se han propuesto nuevos parámetros y técnicas que permitan mejorar la evaluación de estos sistemas de contacto (Ciulli *et al.*, 2006), y por otro lado es de resaltar la importancia de implantar un sistema de no contacto basado en visión, que permita obtener el valor de la rugosidad en un tiempo menor y a bajo costo.

Si bien es cierto que ya se han implantado sistemas de visión basados en análisis de textura (Gadelmawla, 2004; Lee y Tarnng, 2001; Lee *et al.*, 2004), también es cierto que no existe una regla específica o un estándar que permita correlacionar los valores de los parámetros obtenidos con las técnicas de visión y los parámetros de rugosidad. Además las técnicas existentes para extraer la información de la imagen no son precisas y dependen en gran medida del tipo de iluminación y el área de la superficie donde es capturada la imagen.

Se puede resaltar dos áreas de investigación utilizando sistemas de visión: 1) los que se centran en predecir el valor de la rugosidad tratando de

examinar el desgaste de la herramienta con la finalidad de reducir las piezas defectuosas y, 2) los que evalúan el valor final de la rugosidad de la pieza después del mecanizado. En cuanto a la primera forma es de resaltar el trabajo realizado por (Zhang *et al.*, 2006) quienes proponen una estrategia de clasificación, mediante diversos elementos extraídos, como características de forma y métodos de extracción estadística con la matriz de coocurrencia (GLCM) (Haralick, 1979; Haralick *et al.*, 1973) y energía de la textura, este sistema puede etiquetar todos los defectos predefinidos aproximadamente con un 82% de acierto. Mientras que (Castejón *et al.*, 2007) y (Barreiro *et al.*, 2008) han utilizado descriptores geométricos y basados en momentos para determinar el desgaste de la herramienta demostrando que se puede lograr una importante reducción en el tiempo de ciclo y en los recursos necesarios en la monitorización del mecanizado. Igualmente (Alegre *et al.*, 2006, 2009) han diseñado un sistema de visión para predecir el desgaste de la herramienta de corte, con el objetivo de calcular el tiempo de vida que permita aprovechar al máximo la herramienta y su cambio oportuno. Mientras que la segunda posibilidad es determinar el valor de la rugosidad de la pieza mecanizada, con la finalidad de retroalimentar el sistema y asegurar el 100% de efectividad del proceso de inspección y calidad del mecanizado. En este sentido algunas investigaciones han permitido correlacionar los parámetros de rugosidad con descriptores estadísticos de textura. En la investigación realizada por (Al-Kindi *et al.*, 2007) se presenta un método denominado compatibilidad de intensidad topográfica (ITC) que calcula el valor de los parámetros de rugosidad combinando medidas estadísticas como la media y desviación estándar (STD), caracterizándola mediante tres componentes denominados iluminación, reflectancia y características que componen la superficie. Los mismos autores (Al-Kindi *et al.*, 2009) evalúan la viabilidad de los sistemas de visión basándose en los parámetros de rugosidad para diferentes tipos de mecanizado, analizan los valores de R_q , R_{tm} , R_t , R_v , R_p , R_{sk} , R_{ku} , R_{sm} y los comparan sumando el número de resultados globales de todos los parámetros, logrando buenos resultados, aunque el conjunto de datos es limitado debido a que no utilizan una muestra representativa. (Suarez *et al.*, 2008) realiza una clasificación de los valores de la rugosidad en piezas metálicas de acero AISI 6150, mediante la GLCM y la máscara R5R5 de Laws (Laws, 1980a, 1980b), clasificando la rugosidad en dos clases una en baja ($< 6 \mu m$) y otra alta ($> 6 \mu m$) por medio de redes neuronales (RNA), análisis discriminante

lineal (LDA) y cuadrático (QDA), encontrando que las RNA ofrecen un mejor funcionamiento con la GLCM con un error de 5.77% y el kernel de Laws con 5.97%. De la misma forma (Morala-Argüello et al., 2009a, 2009b), utiliza el mismo acero para realizar una clasificación utilizando como descriptores de textura los momentos y GLCM; clasificando el conjunto de datos con K-nn y RNA, obteniendo un error de 6.5% con los momentos de Zernike y RNA.

Otros autores han tratado de resolver el problema combinando distintas técnicas de iluminación (Suarez *et al.*, 2008; Li y Torrance, 2005) y extracción de características o proponiendo nuevos parámetros en tres dimensiones (Zhongxiang, 2009) basándose en que las medidas tradicionales en dos dimensiones no reflejan la topografía real de la superficie. Sin embargo no cuentan con una muestra representativa de las piezas analizadas.

Por lo tanto es de resaltar la importancia de proponer nuevos parámetros mediante sistemas de visión que permitan mejorar el proceso de inspección y evaluación de la rugosidad de la superficie en procesos mecanizados, que puedan determinar si una pieza se encuentra dentro de los rangos mínimos de calidad.

El objetivo principal de esta investigación es proponer un nuevo descriptor basado en la energía de la textura (Laws), que permita clasificar las imágenes de acuerdo a la evaluación de la rugosidad superficial.

Para realizar este proceso se implemento un sistema de visión, el cual permite capturar la imagen de la pieza y extraer la información mediante diferentes descriptores de textura, y posteriormente correlacionarlo con el valor de rugosidad medio (Ra), de acuerdo a la norma UNE 1037:1983, posteriormente se ha seleccionado el mejor de ellos como punto de partida para la propuesta y desarrollo del nuevo kernel denominado R5SR5S.

La clasificación se ha realizado mediante LDA, QDA y K-nn. Finalmente el nuevo kernel es comparado con los descriptores de textura originales de Laws y de Haralick con el objetivo de establecer el buen funcionamiento del descriptor.

2. MATERIALES Y METODOLOGÍA

2.1 Sistema de mecanizado

Debido a que la evaluación de la superficie mediante análisis de imagen exige disponer de una amplia cantidad de muestras, se trató de obtener la mayor cantidad de piezas con diferente valor de rugosidad y un desgaste de la herramienta adecuado para minimizar el coste económico. La planificación de los ensayos se realizó aplicando la metodología de Diseño de Experimentos, de esta manera se logró decidir bajo qué combinación de condiciones de operación se realizaría el mecanizado de las piezas a fin de reducir el número de ensayos a realizar. Se seleccionó un diseño factorial de cuatro niveles y dos factores (velocidad de corte y velocidad de avance), resultando un conjunto total de 16 ensayos, para la velocidad de corte se tomaron valores de: 250, 280, 320 y 350 m/min y para el avance valores de: 0.15, 0.25, 0.4 y 0.55 mm/rev. Se eligieron estos valores por considerarse que cubren un rango suficiente para obtener un conjunto representativo de rugosidades sobre la pieza. Las piezas fueron mecanizadas mediante un torno paralelo multi-torreta MUPEM CNC modelo ICIAR/1/42, con herramientas triangulares con recubrimiento de carburo TNMG 160408PM GC4035 de Sandvik. Como refrigerante se empleó CIMPRIAL C60 al 7-8% de concentración. Las piezas mecanizadas fueron obtenidas a partir de barras de acero del tipo AISI 6150. El diámetro de partida fue de 40 mm y al realizar la operación de cilindrado sobre la pieza, el diámetro final se reduce a 25 mm, empleando una profundidad de pasada de 1.5 mm/rev. La longitud de las piezas mecanizadas fue de 60 mm. Las dimensiones de la plaquita fueron: longitud de la arista de corte 6.35 mm, espesor de plaquita 2.38 mm, radio de punta 0.8 mm.

2.2 Medición de rugosidad

Los parámetros de rugosidad se obtuvieron con un rugosímetro HOMMEL TESTER T 4000 clase 1. Se midieron cinco parámetros de rugosidad (Ra, Rz DIN, Rz ISO, Rpm, Rq), siguiendo la norma UNE-EN ISO 4287:1998, con las siguientes longitudes: longitud básica 0.8 mm, longitud de evaluación 4 mm, longitud de exploración 4.8 mm, longitud de onda de corte o cut-off 0.8. Para el cálculo del valor final de cada parámetro se tomaron tres medidas de cada pieza (Fig. 1), calculando la media aritmética con tres cifras significativas. Finalmente sólo se utiliza el parámetro Ra para compararlo con los descriptores de textura.



Fig. 1. Prototipo de pieza evaluada.

2.3 Adquisición de imagen

El sistema de visión artificial está formado por una cámara AVT Oscar F-810C. Se utilizó un zoom de 2X en la toma de las imágenes. De cada pieza se capturaron 8 imágenes correspondientes a 8 generatrices distintas, resultando 3394 en total, se dividieron en dos clases para evaluar el desempeño de los descriptores, obteniendo 2261 para la clase 1 con rugosidad baja con un valor inferior a $6 \mu\text{m}$ y 1133 para la clase 2 con rugosidad alta mayor a $6 \mu\text{m}$ (Fig. 2). Las imágenes capturadas tenían una resolución de 3372×2469 píxeles.




Fig. 2. Imágenes originales, izquierda clase 1, derecha clase 2.

El montaje estaba compuesto de un zoom industrial 70XL OPTEM, con un tubo de extensión de 1X y lentes 0.5X/0.75X/1.5X/2.0X OPTEM. Las imágenes de las piezas fueron capturadas utilizando un emplazamiento fijo y específico que tiene sujeta la cámara y un sistema de luz difusa (Fig. 3). La pieza fue posicionada en un bloque con forma de "V". El sistema de iluminación consta de una fuente de luz regulada DCR RIII FOSTEC. Para evitar los brillos se utiliza un sistema SCIDI de iluminación difuso NER SCIDI-25-F0. Se utilizó la técnica de iluminación coaxial. Con la finalidad de reducir los errores de iluminación en los bordes; se extrae de cada imagen una zona central comprendida entre los valores de $x_1=0$, $y_1=490$, $x_2=3272$, $y_2=2085$. Una vez extraída esta zona se reduce cinco veces su tamaño original utilizando el método de interpolación de los vecinos más cercanos, logrando una imagen final de 654×319 píxeles y 256 niveles de gris. Se utilizaron filtros paso alto cuyo objetivo principal es destacar los bordes de la imagen. Los filtros utilizados fueron: Sobel, Laplaciano y Canny.




Fig. 3. Sistema de visión

3. DESCRIPCIÓN DE LA RUGOSIDAD

Para evaluar el valor de la rugosidad se ha empleado descriptores de textura en el dominio espacial, utilizando 6 descriptores estadísticos de primer orden, 13 descriptores estadísticos de Haralick obtenidos de la GLCM y 9 kernels de Laws con vecindarios de 5×5 , combinados con los descriptores de primer orden. A continuación se presentan los descriptores utilizados.

3.1. Descriptores de Haralick obtenidos de la GLCM

Este método obtiene información sobre la probabilidad conjunta de que un par de píxeles satisfagan cierta condición. En este método se utiliza la siguiente matriz normalizada de la ecuación (1).

$$N_d(i, j) = \frac{C_d(i, j)}{\sum_i \sum_j C_d(i, j)} \quad (1)$$

Donde C_d es una matriz de coocurrencia. En la construcción de la matriz de coocurrencia los parámetros se basan en la ubicación espacial de los píxeles, las relaciones con su vecindario y el valor de su intensidad, así que debe cumplir ciertas propiedades. Primero debe existir una condición para que determinado píxel sea cuantificado con relación a un vecino. La dirección es la orientación espacial en la cual se evalúa la condición. La distancia representa el número de píxeles de separación entre el par de píxeles evaluados en la condición (Fig. 4). Con base en la GLCM se obtienen los descriptores de textura.

En esta investigación se obtuvo una GLCM para cada una de las direcciones 0, 45, 90 y 135 grados, todos a una distancia fija de 1, 3 y 5 píxeles. Y se analizaron 13 descriptores de textura propuestos por Haralick. Finalmente sólo se formaron dos vectores uno con distancias de 1; y el segundo con distancias de 1, 3 y 5. Por lo tanto el vector 1 se compone de 13 descriptores y el vector 2 de 39 descriptores, por cada dirección.




Fig. 4. Matriz de coocurrencia.

3.2 Descriptores de Laws

El método de Laws consiste en la convolución de la imagen con varios kernels. Cada uno de ellos resalta una característica de textura distinta: L= media ponderada, E= bordes, S= forma o mancha, W= onda, R= rizos o rugosidad, O=oscilación. Al convolucionar la imagen original con un kernel determinado, las nuevas imágenes tendrán valores relacionados con dicha característica. En este trabajo se utilizaron vecindarios de 5x5, ya que son los que han demostrado un mejor rendimiento, los valores de los kernels son los siguientes: L5 = [1 4 6 4 1], E5 = [-1 -2 0 2 1], S5 = [-1 0 2 0 -1], R5 = [1 -4 6 -4 1] y W5 = [-1 2 0 -2 1]. En este trabajo se extrae un total de seis características por kernel para un total de 54 características por cada imagen analizada.

3.3 Propuesta del nuevo descriptor basado en la textura de la imagen

En este paso se pretendía obtener un kernel de convolución, basado en la energía textural de Laws, y que lograra un mayor acierto en la discriminación de las imágenes, evaluando la rugosidad de las piezas metálicas a partir de la textura presente en ellas.

Con ese objetivo, se propusieron y evaluaron diversos descriptores de textura a partir del kernel unidimensional R5. Para solucionar el problema se tuvieron en cuenta algunos puntos débiles de los kernel de Laws, desarrollando diferentes pruebas

como: a) Girar la imagen (kernels) en diferentes ángulos, para solucionar el problema de rotación invariante y comprobar los resultados obtenidos con los kernels de Laws y la GLCM, b) Sumar o restar los kernel con otros kernel de Laws. c) modificar los kernel, consiguiendo un filtro paso bajo o alto, d) convertir los kernel a tres dimensiones y e) aumentar los vecindarios con base en cada kernel. Los kernels propuestos fueron: R5P (1, -2, 3, 4, 5), R5S (1, -4, 2, -4, 1), R5SS (1, -1, 2, -1, 1), R5S3 (1, -8, 6, -8, 1), R5S2 (2, -3, 2, -3, 2).

3.4 Clasificación de la rugosidad

Una vez capturada la imagen se extrae la información aplicando los descriptores de textura. A continuación se detallan en forma general los pasos realizados:

- (1) Después de recortadas las imágenes se agruparon de dos maneras, una definida por el usuario en clase con rugosidad alta y clase 2 con rugosidad baja, y la segunda según los números de clase de rugosidad por la norma UNE 1037:1983 (Tabla 1).

Tabla 1: Clase de rugosidad

Clase	Ra (µm)
Clase 1	0.86 -6.00
Clase 2	6.01-21.29
N4	0.2
N5	0.4
N6	0.8
N7	1.6
N8	3.2
N9-N11	6.3-25

- (2) En la delimitación de fronteras de cada clase las imágenes que tienen un rango de 0,05% entre la frontera de dos clases no son seleccionadas.
- (3) Después se seleccionaron todos los descriptores de acuerdo al método de extracción de características adecuado (Haralick o Laws).
- (4) Luego se analizó descriptor por descriptor con la finalidad de comprobar el de mejor rendimiento al correlacionarlo con el valor Ra.
- (5) Después se implementó el filtrado (Sobel, Laplaciano, Canny) y pre-procesamiento.
- (6) Después se comprobó la dimensión de las imágenes en distintas direcciones y franjas (vertical 155x319 píxeles, horizontal 654x21 píxeles), con la finalidad de reducir el tiempo de ejecución del software y la pérdida de información.

- (7) **En este paso se analizan las imágenes de dos maneras, una sin promediar las imágenes de la misma pieza y otra promediándolas.** La segunda opción se implantó debido a que en las pruebas con el rugosímetro los valores de Ra de una misma pieza variaban en su precisión, así que se debió promediar para normalizar en un único valor, igualmente en esta prueba se realiza lo mismo pero con las imágenes, ya que cada imagen cambia sus valores de rugosidad de una a otra, a pesar de ser obtenidas de la misma imagen. De esta manera nos aseguramos que dentro de las 8 imágenes de cada pieza todas queden en el mismo rango al promediar sus valores. Para esto se promedian los píxeles ubicados en la misma posición de cada una de las imágenes.
- (8) Luego se analizaron con los tres métodos de clasificación (LDA, QDA y K-NN).
- (9) Finalmente los resultados de los descriptores, son correlacionados con los valores de Ra del rugosímetro. Repitiendo el proceso con la finalidad de encontrar el mejor descriptor-clasificador.

En el experimento se utilizó para entrenamiento y prueba el 60% y 40% de las muestras respectivamente.

Con la finalidad de evitar errores se utilizó de forma aleatoria la división de las clases, donde se obtienen 904 en la clase 1 y 453 imágenes en la clase 2, y 1357 por 680 para entrenamiento respectivamente. Para la clase 1 las imágenes seleccionadas tenían un valor de rugosidad comprendido entre 0,86 μm y 6 μm , la clase 2 entre 6,01 y 21,29 μm . La clase 1 comprendía los números N6, N7, N8 y la clase 2 eran N9 y N10 de la norma UNE 1037:1983.

4. RESULTADOS

Se procedió a examinar los descriptores de rugosidad propuestos y si desempeñaban una mejor solución para clasificar la textura de las imágenes de acuerdo a su rugosidad.

El proceso se desarrolló siguiendo los pasos mencionados anteriormente, clasificando las dos clases. Como clasificador se utilizó K-NN y los descriptores estadísticos: media, STD, kurtosis y skewness, sin promediar los resultados de estos descriptores para encontrar el error final, o sea utilizando la primera opción del paso 7 del numeral 4.

Tabla 2: Porcentaje de error de los nuevos kernels

KERNEL	K	Clase1	Clase2	%E
R5s2R5s2	11	1840	1961	14.25
R5s3R5s3	11	1840	1961	14.89
R5ssR5ss	19	1840	1961	10.04
R7sR7s	11	1840	1961	14.23
R5sR5s	9	1840	1961	8.55
R5pR5p	23	1840	1961	25.12

El objetivo fundamental era encontrar cuál de los seis kernels era el de mejor desempeño como discriminador de la textura. De acuerdo a los resultados se concluye que los kernels que aumentan la discriminación son: R5SSR5SS con un error de 10.04% y R5SR5S con un error de 8.55%.

En estos resultados (Tabla 2) se aprecia una clara tendencia que favorece a los kernels donde se modificó el núcleo interno, esto se debe a la dirección de la huella que ha dejado el mecanizado, favoreciendo este tipo de kernels. Finalmente se puede observar que el kernel R5SR5S es el de mejor desempeño con un error de 8,55%.

De los kernels de Laws los mejores resultados se obtienen con R5R5, E5R5 y E5E5, seleccionando el kernel R5R5 al obtener un error de 6.41% con LDA y QDA.

En cuanto a los descriptores de Haralick se han formado dos vectores: uno con distancias de uno y trece descriptores; y el segundo con distancias de 1, 3, 5 formando un vector de 39 descriptores. En los dos vectores los resultados mejoran levemente cuando se realiza una clasificación QDA, y disminuyen su clasificación cuando es con el LDA.

El inconveniente con los descriptores de Haralick es la cantidad de descriptores que se deben utilizar para encontrar una buena solución. De acuerdo a la matriz de estructura (Tabla 3) se puede concluir que los descriptores que más influyen en la discriminación son: la segunda medida de información de la correlación (SC), primera medida de información de la correlación (FC), correlación (CO) y la suma de la entropía, con distancia de 1 y dirección de cero grados. Con lo cual se puede concluir que estos descriptores son los más aptos para una correlación con el kernel propuesto.

Tabla 3: Matriz de estructura vector 1.

Función 1	
Segunda medida de correlación	-0.731
Primera medida de correlación	0.721
Correlación	-0.669
Suma entropía	-0.318
Momento inverso	-0.198
Suma varianza	0.179
Suma promedio	0.173
Contraste	0.140
Entropía	-0.119
Varianza	0.113
Diferencia varianza	-0.104
Diferencia entropía	0.084
Energía	0.045

Los errores de estos descriptores son de 9.8% con LDA, 7.52% con QDA y 7% para la FC, y para la SC es 8.92% y 9.36% respectivamente. Al combinar estos tres descriptores se obtienen un error de 6.63% con LDA y 7.66% con QDA. En forma general el vector 2 ofrece mejores resultados al combinar todos los descriptores sin embargo el tiempo de proceso es bastante elevado. Al repetir los experimentos con el kernel propuesto R5SR5S y los descriptores de primer orden se obtiene un error de 4.13% con LDA y 2.87% con QDA. Con estos resultados en la clasificación, nos ponen de manifiesto que el modelo planteado funciona bastante bien dada su capacidad discriminatoria. Los coeficientes que recogen la Tab8 nos permiten concluir que las variables que tienen un mayor poder explicativo sobre la variable independiente son la STD, Rango y la Entropía.

Para evaluar cada una de las variables volvemos a utilizar el análisis discriminante, utilizando cada una en forma unitaria, con la finalidad de determinar el mejor descriptor. Con estos resultados cuantitativos se puede comprobar el buen poder de discriminación de la STD con un 3.83 de error, el rango con un 6.41%, entropía 10.53%, los últimos tres descriptores tienen una tendencia a empeorar la clasificación, además que sus valores a veces decrecen, lo cual sería un inconveniente en la correlación de la rugosidad. Los resultados de clasificación con QDA son de 2.87% disminuyendo en 1.26% con respecto a LDA. Se puede concluir que los resultados disminuyen y se mantienen los mismos descriptores que ofrecen buenos resultados para la clasificación con LDA, logrando el menor error con la STD de 3.17%, rango 6.41%, entropía 10.02%, kurtosis 19.46%, media 22.93% y skewness 33.77%.

Finalmente seleccionamos los descriptores más representativos en cada uno de los métodos. De los descriptores de Haralick se seleccionan la correlación (C), primera medida de correlación (FC), segunda medida de correlación (SC) y la combinación de los tres descriptores anteriores (CFS); de Laws se selecciona R5R5 y el nuevo kernel R5SR5S junto con la STD. En la Fig. 11 se puede observar la diferencia de error de estos descriptores, comprobando que el descriptor propuesto obtiene un error de 2.87% con QDA mejorando la tasa de acierto de los otros descriptores. Si analizamos trabajos donde se utilizaron materiales e imágenes semejantes (Morala-Argüello et al., 2009a, 2009b), los cuales presentaron errores de clasificación bastante elevados al emplear momentos de zernike (6,5%), Legendre (9%) y GLCM (10%); y comparamos los resultados al utilizar el kernel propuesto de Laws, observamos una mejora considerable en la clasificación. Esto se debe al proceso donde se promedian los descriptores de textura obtenidos en las imágenes de una misma pieza, logrando una normalización de los valores que se obtienen.

5. CONCLUSIONES

En este artículo se propone un nuevo método para mejorar el control de calidad de piezas metálicas, después del proceso de mecanizado en operaciones de torneado; correlacionando el valor de la rugosidad con un nuevo descriptor de textura basado en Laws. Los resultados del kernel propuesto combinado con la desviación estándar permiten clasificar las imágenes con una tasa de acierto de 95.87% con LDA y 97.3% con QDA, estos resultados demuestran que la máscara R5SR5S es una buena alternativa para evaluar el valor de la rugosidad y mejorar el proceso de control de calidad de nuevos productos.

RECONOCIMIENTO

Agradecemos a la Universidad de León, España, por la ayuda en la realización de las pruebas de mecanizado y sistemas de visión.

REFERENCIAS

- Ciulli, E., Ferreira, L., Pugliese, G., Tavares, S. (2008). "Rough contacts between actual engineering surfaces: Part i. simple models for roughness description". *Wear*, Vol. 264, No. 11-12, pp. 1105 – 1115.

- Gadelmawla, E.S. (2004). "A vision system for surface roughness characterization using the gray level co-occurrence matrix". *NDT & E International*, Vol. 37, pp. 577 - 588.
- Lee, B. Y. y Tarng, Y S. (2001). "Surface roughness inspection by computer vision in turning operations". *International Journal of Machine Tools and Manufacture*, Vol. 41, pp. 1251-1263.
- Lee, B. Y., Yu, S. F. y Juan, H. (2004). "The model of surface roughness inspection by vision system in turning". *Mechatronics*, Vol. 14, pp. 129-141.
- Zhang, X., Krewet, C. y Kuhlenkötter, B. (2006). "Automatic classification of defects on the product surface in grinding and polishing". *International Journal of Machine Tools and Manufacture*, Vol. 46, pp. 59 - 69.
- Haralick, R M. (1979). "Statistical and Structural Approaches to Texture". *Proceedings of the IEEE*, Vol. 67, pp. 786-804.
- Haralick, R. M., Shanmugam, K. y Dinstein, I. (1973). "Textural features for image classification". *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. SMC-3, pp. 610-621.
- Castejón, M., Alegre, E., Barreiro, J. y Hernández, L. (2007). "On-line tool wear monitoring using geometric descriptors from digital images". *International Journal of Machine Tools and Manufacture*, Vol. 47, pp. 1847 - 1853.
- Barreiro, J., Castejón, M., Alegre, E. y Hernández, L. (2008). "Use of descriptors based on moments from digital images for tool wear". *International Journal of Machine Tools & Manufacture*, Vol. 48, pp. 1005-1013.
- Alegre, E., Barreiro, J., Fernández, R. y Castejón, M. (2006). "Design of a computer vision system to estimate tool wearing". *Material Science Forum*, Vol. 526, pp. 61-66.
- Alegre, E., Alaiz-Rodríguez, R., Barreiro, J. y Ruiz, J. (2009). "Use of contour signatures and classification methods to optimize the tool life in metal machining". *Estonian Journal of Engineering*, Vol. 15, págs. 3-12.
- Al-Kindi, G A y Shirinzadeh, B. (2007) "An evaluation of surface roughness parameters measurement using vision-based data". *International Journal of Machine Tools and Manufacture*, Vol. 47, pp. 697-708.
- Al-Kindi, G A y Shirinzadeh, B. (2009). "Feasibility assessment of vision-based surface roughness parameters acquisition for different types of machined specimens". *Image and Vision Computing*, Vol. 27, pp. 444-458.
- Suarez, S., Alegre, E., Barreiro, J., Morala Arguello, P. y Gonzalez Castro, V. (2009). "Classification and correlation of surface roughness in metallic parts using texture descriptors". *Annals of DAAAM for 2009 & Proceedings of the 20th International DAAAM Symposium*, pp. 1293-1295. Vienna, Austria.
- Laws, K I. (1980a). "Rapid texture identification. In SPIE". *Image Processing for Missile Guidance*, Vol. 238, pp. 376-380.
- Laws, K I. (1980b). "Textured Image Segmentation". Ph.D. Dissertation, University of Southern California.
- Morala-Argüello, P., Barreiro, J., Alegre, E. y González-Castro, V. (2009). "Application of textural descriptors for the evaluation of surface roughness class in the machining of metals". *3rd Manufacturing Engineering Society International Conference (MESIC'09), Conference Proceedings*, pp. 833-839.
- Morala-Argüello, P., Barrerio, J., Alegre, E., Suarez, S. y González-Castro, V. (2009a). "Qualitative surface roughness evaluation using Haralick features and wavelet transform". *Annals of DAAAM for 2009 & Proceedings of the 20th International DAAAM Symposium*, pp. 1241-1242. Vienna - Austria.
- Suarez, S., Alegre, E., Morala-Argüello, P., Barreiro, J. y González-Castro, V. (2008b). "Evaluación de diferentes tipos de iluminación para la clasificación de la rugosidad de piezas metálicas mediante análisis de imagen". *XXIX Jornadas de Automática*. Tarragona - Spain.
- Li, H. y Torrance, K. E. (2005). "An experimental study of the correlation between surface roughness and light scattering for rough metallic surfaces". *Advanced Characterization Techniques for Optics, Semiconductors, and Nanotechnologies II. Proceedings of the SPIE*, Vol. 5878, pp. 249-263.
- Zhongxiang, H., Lei, Z., Jiayu, T., Xuehong, M. y Xiaojun, S. (2009). "Evaluation of three-dimensional surface roughness parameters based on digital image processing". *The International Journal of Advanced Manufacturing Technology*, Vol. 40, pp. 342-348.