

Clasificación De Piezas Metalmecánicas Basado En Algoritmos Inteligentes Implementando Procesamiento Digital De Imágenes

Margarita R. Gamarra A.

Politécnico de la Costa Atlántica, Barranquilla, Colombia, mgamarraa@pca.edu.co

Francisco A. Bertel R.

Politécnico de la Costa Atlántica, Barranquilla, Colombia, fbterlr@pca.edu.co

ABSTRACT

This work aims to develop a computational tool based on intelligent algorithms for classification of three types of metalworking parts. For this, it is necessary to design an intelligent system able to detect the piece by digital image processing, effective feature selection using genetic algorithms (GA) and classification with Artificial Neural Networks (ANN), all integrated in MatLab specialized software. At present, the metalworking companies show great interest in automating their processes, thereby an intelligent system to support the classification made by operators is sought, due to sometimes their criteria results subjective. In this work appears that classifier implemented with ANN results in lower error percentage compared to the k-means classifier, even with a reduced size of the confidence interval.

Keywords: Image Processing, Genetic Algorithms, Artificial Neural Network.

RESUMEN

Este trabajo tiene como objetivo el desarrollo de una herramienta computacional basada en algoritmos inteligentes para la clasificación de tres tipos de piezas metalmecánicas. Para ello, se hace necesario diseñar un sistema inteligente capaz de detectar la pieza mediante procesamiento digital de imágenes, selección efectiva de características mediante Algoritmos Genéticos (GA) y clasificación con Redes Neuronales Artificiales (RNA), todo esto integrado en el software especializado MatLab. En la actualidad, las compañías metalmecánicas muestran gran interés por la automatización de sus procesos, por ello se busca soportar la clasificación que hacen sus operarios con un sistema inteligente que detecte el tipo de pieza ya que en ocasiones su criterio resulta subjetivo. En este trabajo se obtiene que el clasificador implementado con redes neuronales resulta en un porcentaje de error inferior al clasificador de los k-vecinos, incluso con rango reducido del intervalo de confianza.

Palabras claves: Procesamiento de imágenes, Algoritmos Genéticos, Redes Neuronales Artificiales.

1. INTRODUCCIÓN

En la industria metalmecánica es importante la correcta clasificación de sus piezas para obtener un producto de excelente calidad. La inspección que se realice a cada una de sus partes obedece no sólo a criterios de diseño, sino también a parámetros de seguridad. Los errores en la clasificación de las piezas se presentan por fallas en las máquinas productoras, sobretodo en piezas que son visualmente muy similares. En algunos casos, un operario es el encargado de realizar la revisión final, aumentando el tiempo de inspección de la pieza.

Esta inspección es de forma visual, utilizando instrumentos de medición para características como el diámetro y peso. En la actualidad, es utilizado un proceso de clasificación mediante técnicas de procesamiento digital de imágenes el cual es conocido como sistema AVI (inspección visual automática) (Domingo, 2002). Este sistema presenta un alto nivel de confiabilidad, sin embargo, necesita del criterio de un operario que evalúe las imágenes

para así determinar si la pieza requiere un reproceso o su falla es aceptable, en el caso de control de calidad.

Después de un período de tiempo relativamente corto la agudeza visual se deteriora, incluso en el caso de que la clasificación sea relativamente simple (Giró, 2005). Factores como la fatiga y la monotonía misma del trabajo de las personas encargadas de examinar hacen que se sigan presentando fallas. Por esta razón, se pretende diseñar un sistema inteligente para la clasificación de piezas en este sector de la industria y reducir considerablemente los errores que se presentan en la actualidad.

Este proyecto se enfoca en la parte de clasificación de piezas metálicas, pues es un campo con gran aplicabilidad y que merece especial atención, para fabricar un producto final de excelente calidad. Muchos sectores de la industria, como el de alimentos y la metalmecánica han automatizado la mayoría de sus procedimientos en busca de una mejor calidad en los productos y rapidez en la elaboración o transformación de los mismos (Giró, 2005).

La inspección visual realizada por humanos en fábricas, supone aproximadamente el 10% de los costes de producción, y su eficiencia está en torno al 60% (Davidson, Chu, & Ryks, 1999). Además, no pueden proporcionar funciones avanzadas de clasificación. Por esta razón, se hace necesario recurrir a otras alternativas tecnológicas para realizar el proceso de clasificación de las piezas.

Una alternativa es mediante procesamiento digital de imágenes, pues permite obtener características de las piezas. También es necesario tomar decisiones respecto a éstas, de acuerdo a la clasificación realizada. Para esto, se implementan técnicas inteligentes luego del procesamiento de la imagen.

El desarrollo del proyecto en mención encuentra su razón de ser en los procesos de la industria metalmecánica. Se ha escogido la industria metalmecánica, pues tiene una creciente participación en los mercados colombianos y mundiales. El proyecto a ejecutar representa un adelanto tecnológico y científico, pues ofrece una técnica inteligente aplicada a la clasificación de piezas metalmecánicas en forma automática mediante procesamiento digital de imágenes y algoritmos inteligentes.

2. ESTADO DEL ARTE

Existen numerosas investigaciones a nivel mundial acerca de las técnicas utilizadas en la clasificación en diferentes sectores de la industria, mediante inspección visual y técnicas no destructivas. Entre ellas se encuentran las desarrolladas por universidades e instituciones técnicas y unas cuantas a cargo de empresas del sector automotriz. Una investigación relacionada con la identificación y clasificación de granos de café se muestra en (Bustamante, 2004). Este proyecto utiliza procesamiento digital sobre una imagen para luego ser enviada a un PLC u otro controlador, el cual destina el grano de café a un siguiente proceso de acuerdo a ciertas características como color y tamaño. Para el diseño de proyectos con granos de café es fundamental establecer las tonalidades que van desde el verde hasta el rojo. Como resultado principal se puede mencionar lo siguiente:

- El sistema es capaz de clasificar en cuatro clases, las cuales se pueden ajustar cambiando los umbrales. Sin embargo, para obtener un sistema de selección automático confiable y robusto, sería necesario contar con procedimientos de autocalibración para ajustar los parámetros de selección.

En (Rodríguez, 2012) se presenta un sistema automatizado de inspección no destructiva de materiales usando ultrasonidos para la detección de heterogeneidades en piezas metálicas. Para ello, utilizaron guías lineales que se han automatizado con motores paso a paso cuyos movimientos se controlan desde el computador. Una vez detectados los defectos, se permite una posterior clasificación de los defectos según morfología, posición y tamaño con programas que utilizan algoritmos basados en Reconocimiento de Patrones. Las principales conclusiones de esta investigación son:

- Aumento de la eficiencia y precisión en la inspección de piezas metálicas, aquí se reducen tanto el tiempo de inspección como los errores de detección a la hora de determinar si una pieza es apta o no para su utilización en la industria y permite el almacenamiento de una gran cantidad de datos.

- Se ha obtenido una buena clasificación de los defectos, sobre todo en cuanto a su morfología, aunque no se ha podido determinar unas características determinantes que sean comunes para todos los clasificadores considerados.

La investigación desarrollada en (Jeong, 2010) presenta un método de selección de características usando un algoritmo de selección hacia atrás que reduce el conjunto total a solamente aquellas que son más relevantes para la clasificación, utilizando el estadístico kappa. Este método es aplicado a la clasificación de defectos en acero a partir de una imagen. Los principales resultados son:

- Los resultados experimentales muestran que el método propuesto asegura una alta tasa de verdaderos positivos comparado con otros algoritmos.
- Las características relevantes en la clasificación de defectos en acero, pueden ser estudiadas para mejorar el desempeño de sistemas de inspección de defectos.

La investigación presentada en (Ramírez & Chacón, 2005) muestra una aplicación de redes neuronales en procesos de clasificación, enfocado a la detección de defectos en madera. El artículo describe un clasificador neuronal el cual distingue entre 7 tipos de defectos en madera. Las características fueron extraídas de una imagen de la madera, usando filtros de Gabor 2D. Se utilizó el método de Análisis de Componentes Principales para reducir el número de características. Los principales resultados son:

- El reconocimiento obtenido con las muestras de entrenamiento fue del 86% y para las muestras de prueba fue de 83.91%. Este resultado se considera aceptable dado que el reconocimiento de un inspector humano está entre el 75% y el 85%.
- El desempeño del clasificador depende fuertemente de sus entradas. La etapa más importante en el diseño de un sistema de clasificación es decidir qué características se tomarán como entrada a la red neuronal.

Debido al interés por la automatización y calidad que tiene el sector industrial y en particular las empresas que manejan piezas metalmecánicas es necesario soportar la clasificación de piezas que hacen los operarios por un sistema inteligente que detecte características propias de las piezas y mejore la inspección de las mismas. A pesar de todas las investigaciones realizadas acerca de inspección visual y reconocimiento de patrones, un método diseñado para reconocer las fallas en un producto, difícilmente servirá para detectar las fallas en otro producto que tenga otra forma o color. Es necesario destacar que la clasificación se realiza en un sistema automático de inspección luego de una etapa de entrenamiento supervisado. En esta etapa se hace un estudio estadístico de las características que se extraen de objetos cuyas fallas sean conocidas a priori (Domingo, 2002).

En Colombia no se han realizado muchas investigaciones en la industria metalmecánica, como lo han hecho para otros sectores como el de la salud o industrias de alimentos. Este proyecto busca arrojar criterios de clasificación automática para piezas metalmecánicas, utilizando técnicas que puedan decidir acerca de la clasificación de las mismas.

3. ENFOQUE PROPUESTO

El enfoque propuesto para la clasificación de tres tipos de piezas metálicas (Housing, Reductor y Relación) se basa en una inspección visual. Una primera etapa consiste en implementar técnicas de procesamiento digital de imágenes para extraer características representativas de cada pieza. Sin embargo no todas estas características permiten diferenciar entre estas tres piezas.

Para esto se realiza un proceso de selección de características mediante Algoritmos Genéticos (GA), de manera que en el proceso de clasificación se utilicen solamente las características más discriminantes. Para la clasificación de las piezas se implementa una Red Neuronal Artificial (RNA), teniendo como entrada las características seleccionadas por el AG. En la Figura 1 se muestra un diagrama sobre el sistema propuesto.

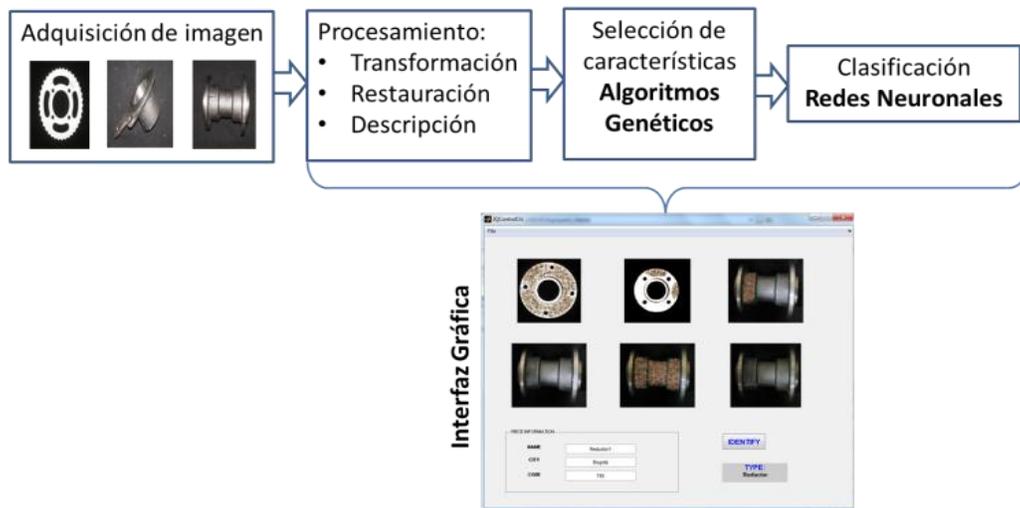


Figura 1: Esquema propuesto para la clasificación de las piezas.

Este proyecto está enfocado en la integración de procesamiento digital de imágenes con inteligencia artificial para desarrollar un sistema autónomo. Esta herramienta permitirá a los expertos humanos clasificar de manera adecuada la pieza evaluada.

3.1 PROCESAMIENTO DIGITAL DE IMÁGENES

Una imagen puede ser definida como una función bidimensional, $f(x,y)$, donde x e y con coordenadas espaciales, y la amplitud de f es llamada intensidad de los niveles de gris en ese punto (Gonzalez & Eddins, 2004). En el proceso de control de calidad se implementaron las siguientes etapas:

3.1.1 ADQUISICIÓN DE LA IMAGEN

Esta primera etapa tiene un importante papel, porque afecta la calidad de la imagen y el desempeño de las siguientes etapas. Para la adquisición de las imágenes, se tomaron las fotografías que servirían como base de datos para el procesamiento, pues no se contaba con dicha base. Estas fotografías corresponden a las vistas o perspectivas de cada una de las tres piezas.

Estas piezas son: Relación, Punta de Housing y reductor central, que se muestran en la Figura 2.



Figura 2: Piezas seleccionadas: relación, punta de housing y reductor central

Se tomaron varias fotografías para cada tipo, teniendo en cuenta que las condiciones de iluminación, posición y ángulo deberían ser las mismas para cada pieza, para que no se presentaran inconvenientes en el procesamiento. Una solución dada fue implementar un soporte para la cámara fotográfica, de manera que se pudiera controlar las posibles variaciones en la distancia, posición y ángulo y se manejó cuidadosamente la iluminación. También se utilizó un fondo negro opaco, para que contrastara con las piezas metálicas y facilitara la identificación cuando se le hiciera el tratamiento a las imágenes.

3.1.2 PROCESAMIENTO

Esta etapa está compuesta de varios procesos que mejoran la imagen para extraer sus características:

Cambiar el tamaño de la imagen para resaltar algunas cualidades o ajustar las proporciones. Una vez el programa diseñado en Matlab® lee la imagen, se modifica su tamaño, el cual es adaptado a ciertos límites que facilitan su procesamiento (esto se ha determinado con pruebas previas para cada imagen). De esta manera cada uno de los tres tipos de pieza es mostrado en la interfaz con un tamaño diferente.

Filtrado de la imagen: el método escogido para reducción de ruido en este caso son los filtros espaciales. Para el proceso de filtrado de la imagen se hizo uso de un filtro adaptativo de mediana. Los parámetros de dicho filtro son diferentes para cada pieza, pues aunque se controlaron las condiciones de iluminación, algunas vistas son más brillantes y tienen un mayor contraste con el fondo, como es el caso de la relación. Estos parámetros se seleccionaron a partir de pruebas realizadas a cada vista, escogiendo los que arrojaran mejores resultados en el filtrado.

Binarización: este proceso facilita hacer distinción entre la pieza a evaluar y su fondo. En este momento es posible extraer algunas características de la pieza segmentada. Los resultados del procesamiento de imágenes corresponden a valores numéricos (porcentajes, cantidad de huecos, distancias) para cada característica.

3.1.3 REPRESENTACIÓN Y DESCRIPCIÓN:

Representar una región abarca dos opciones básicas: (1) se puede representar una región en términos de sus características externas (su forma) o (2) se puede representar en términos de sus características internas (región). Dos tipos de descriptores son considerados importantes para representar las piezas metálicas de otro tipo de piezas: descriptores de forma (utilizando descriptores de Fourier) y descriptores regionales (descriptores de textura).

3.2 SELECCIÓN DE CARACTERÍSTICAS

Las técnicas de inteligencia artificial simulan el comportamiento humano, relacionado a la toma de decisiones y el análisis de una situación específica. El algoritmo implementado consiste en aplicar un proceso de selección de características mediante un algoritmo genético.

Este algoritmo toma inicialmente el vector con todas las características extraídas en la etapa de procesamiento de imágenes. Mediante una función de evaluación (en este caso corresponde al porcentaje de error) determina los individuos (características) que mejoran este índice. Se aplican procesos evolutivos (mutación, cruce, generación de nuevos individuos) a través de varias generaciones para finalmente seleccionar el vector más adecuado.

El vector de características inicial para el reconocimiento de piezas es el siguiente:

- 1) Área
- 2) Número de huecos
- 3) Diámetro
- 4) Excentricidad
- 5) Longitud de eje mayor
- 6) Longitud de eje menor
- 7) Perímetro
- 8) Media
- 9) Desviación estándar
- 10) Suavidad
- 11) Tercer momento estadístico
- 12) Uniformidad
- 13) Entropía

3.3 CLASIFICACIÓN DE PIEZAS

La red neuronal diseñada es alimentada con las características seleccionadas por el algoritmo genético, las cuales son normalizadas para que todas las entradas tengan igual importancia. Se utiliza un Perceptrón multicapa, estructura Feed-forward con aprendizaje supervisado. Se implementa el algoritmo de aprendizaje Backpropagation, con una única capa oculta. El número de neuronas en la capa oculta estabiliza las interconexiones entre las neuronas de entrada y las de salida. En este caso se utilizaron 20 neuronas en la capa oculta. Esta caracterización se llevó a cabo de manera experimental.

4. PRUEBAS Y RESULTADOS

Una vez la imagen de cada pieza ha sido procesada y las características son extraídas, un vector de características es la entrada a la función de evaluación (fitness function) del AG. Los individuos (características) seleccionados de acuerdo con parámetros de cruce, mutación y reproducción del AG, son aquellos que logren obtener un menor porcentaje de error en la clasificación. Internamente, la función de evaluación utiliza un clasificador de los k-vecinos para obtener el porcentaje de aciertos con las características seleccionadas. En total se evaluaron 32 imágenes de cada pieza, tomando el 70% para entrenamiento y el 30% para validación (Molinero, 2002) (Zamorano, 2005).

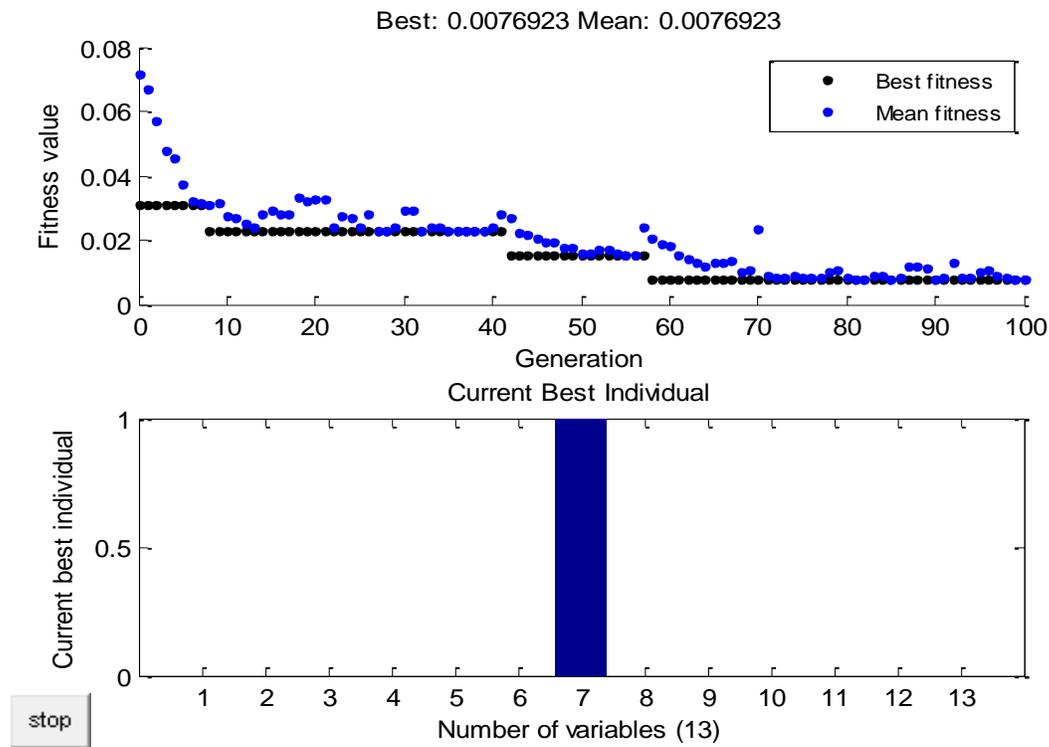


Figura 3: Comportamiento del algoritmo genético para la clasificación de las tres piezas.

En la Figura 3 se presenta la evolución por generación del valor objetivo del algoritmo genético, con los valores para el mejor valor y el valor promedio en cada población generada. También se presentan las características seleccionadas.

Para este caso, se obtuvo un porcentaje promedio de error en la clasificación del 3.7%, solamente con la selección de la característica número 7, que corresponde a la característica *Perímetro* de la pieza a seleccionar. Si todos los descriptores son extraídos, el costo computacional se incrementa aproximadamente en 2mS.

Para obtener el desempeño de la red neuronal implementada, se utiliza la matriz de confusión, la cual presenta cómo el clasificador selecciona las clases, comparando las clases reales con las clases clasificadas. Algunos indicadores de desempeño se basan en la matriz de confusión (Moliner, 2002):

- Proporción de Verdaderos Positivos (efectividad): $PVP = VP / (VP + FN)$
- Proporción de Falsos Negativos (Error Positivo): $PFN = FN / (VP + FN)$
- Proporción de Verdaderos Negativos (Especificidad): $PVN = VN / (VN + FP)$
- Proporción de Falsos Positivos (Error Negativo): $PFP = FP / (VN + FP)$

La curva ROC muestra la relación entre efectividad y especificidad del clasificador, un incremento en la sensibilidad es acompañado por un decremento en la especificidad. Esto quiere decir que la curva ROC muestra la relación entre muestras clasificadas correctamente (PVP) y muestras que no pertenecen a la clase pero fueron clasificadas dentro de esa clase (PFP) (Sandoval & Prieto, 2007).

En el espacio ROC la PFP es dibujada como una variable independiente y PVP como la variable dependiente. Cada clasificador es representado por el punto (PFP, PTP). La curva más aproximada a la esquina izquierda-arriba, en el espacio ROC, representa el test más preciso, esto significa que hay mayor cantidad de éxitos. La curva más cercana a la diagonal de 45° en el espacio ROC, representa la aproximación menos exitosa.

En la Figura 4 se presenta la matriz de confusión, para el reconocimiento de las tres piezas metalmecánicas:

Output Class	1	2	3	
1	32 33.3%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	32 33.3%	3 3.1%	91.4% 8.6%
3	0 0.0%	0 0.0%	29 30.2%	100% 0.0%
	100% 0.0%	100% 0.0%	90.6% 9.4%	96.9% 3.1%
	1	2	3	
	Target Class			

Figura 4: Matriz de confusión para las tres piezas evaluadas.

De acuerdo con estos resultados, la clasificación con redes neuronales tuvo un porcentaje de aciertos del 96.9%.

En la Figura 5 se presenta la curva ROC para la clasificación de las tres piezas:

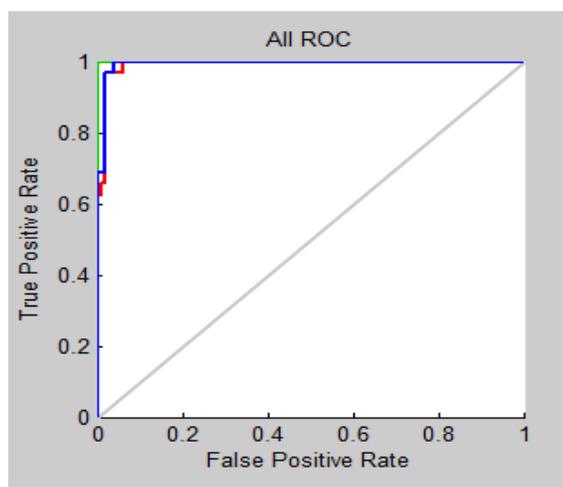


Figura 5: Curva ROC para las tres piezas evaluadas.

Según los resultados obtenidos para la curva ROC, esta se aproxima a la esquina superior izquierda, lo cual indica un mayor número de éxitos en la clasificación.

En la Tabla 1 se presenta una comparación del porcentaje de error entre el clasificador de los k-vecinos (utilizado en la función de costo del GA) y el clasificador con RNA, utilizado con la totalidad de muestras de las piezas.

Tabla 1: Porcentaje de error para los clasificadores.

%Error (KNN)	Intervalo de confianza	%Error (ANN)	Intervalo de confianza
3.70%	2.5%-4.8%	2.85%	2.4%-3.2%

De acuerdo con estos resultados, el clasificador con redes neuronales tuvo un porcentaje de error de 2.85%, inferior al clasificador de los k-vecinos, con un intervalo de confianza de 2.4%-3.2%. Esto demuestra que para este caso de aplicación, la clasificación de piezas realizada con redes neuronales presenta un mejor desempeño que el clasificador de los k-vecinos.

5. CONCLUSIONES

El sistema de clasificación de piezas metalmecánicas desarrollado muestra cómo se pueden implementar técnicas de las áreas de procesamiento digital de imágenes e inteligencia computacional en el reconocimiento automático de productos en un sector específico de la industria.

A partir de los resultados obtenidos con la metodología propuesta para reconocimiento de las piezas se puede concluir lo siguiente:

- La etapa de adquisición de la imagen tiene un papel importante dentro del proceso de adaptación de la imagen. Las condiciones de iluminación, posición y ángulo deben ser iguales para cada pieza, pues estas influyen en la selección del umbral de binarización y en el proceso de filtrado.
- El AG selecciona aquellas características que permiten el reconocimiento de las tres piezas trabajadas. Con menos características extraídas se reduce el costo computacional en el reconocimiento automático.
- El Perímetro resultó ser la característica más adecuada para el reconocimiento entre las tres piezas. Esto se puede reafirmar visualmente, pues el descriptor más distintivo entre las tres piezas es su forma geométrica externa (Ver Fig. 2)

- La clasificación de las piezas con redes neuronales presentó un porcentaje de error menor que al implementar el clasificador de los k-vecinos. Una vez la red ha sido entrenada, la configuración delimitada permite el reconocimiento automático de las piezas.
- La implementación de algoritmos inteligentes en la clasificación de piezas metalmecánicas se aplica al proceso de selección efectiva de características y la clasificación, arrojando resultados óptimos (menor costo computacional y menor porcentaje de error en la clasificación).
- La interfaz desarrollada le permite al usuario realizar varias tareas con las imágenes de las piezas: cargar varias imágenes de la pieza, identificar la pieza, guardar las imágenes e información digitada de la pieza.

REFERENCIAS

- Bustamante, A. (2004). *Prototipo Para La Selección Automática de Café en Cereza*. Manizales: Universidad Nacional, Sede Manizales.
- Davidson, V., Chu, T., & Ryks, J. (1999). Fuzzy Methods Automated Inspection of Food Products. *IEEE Xplore*.
- Domingo, M. (2002). Inspección Visual Automática. *Primer Congreso Internacional de Ingeniería Mecatrónica*. Lima.
- Giró, S. (2005). *Visión Artificial en la Industria Alimentaria*. Obtenido de http://www.jcee.upc.es/JCEE2005/pdf_ponencias/conferencia_infaimon.pdf
- Gonzalez, W., & Eddins. (2004). *Digital Image Processing Using MATLAB*. Prentice Hall.
- Jeong, D. (2010). Feature Selection for Steel Defects Classification. *International Conference on Control, Automation and Systems*. Gyeonggi-do, Korea.
- Molinero, L. (2002). Métodos Estadísticos De Clasificación. *Asociación de la Sociedad Española de Hipertensión*.
- Ramírez, G., & Chacón, M. (2005). Clasificación de Defectos en Madera Utilizando Redes Neuronales Artificiales. *Computación y Sistemas*, 9(1), 17-27.
- Rodriguez, C. (2012). *Sistema Automatizado de Detección de Defectos en Piezas Metálicas Mediante Ensayos no Destructivos con Ultrasonido*. Cantabria: Universidad de Cantabria.
- Sandoval, Z., & Prieto, F. (2007). Caracterización De Café Cereza Empleando Técnicas De Visión Artificial. *Revista Facultad Nacional de Agronomía*, 60(2), 4105-4127.
- Zamorano, J. (2005). *Clasificación de patrones: Evaluación*. Escuela Politécnica Superior.

Authorization and Disclaimer

Authors authorize LACCEI to publish the paper in the conference proceedings. Neither LACCEI nor the editors are responsible either for the content or for the implications of what is expressed in the paper.