Visión artificial basada en aprendizaje automático para la categorización de defectos superficiales en fundición

MACHINE VISION FOR SURFACE DEFECTS CATEGORISATION IN FOUNDRIES BASED ON MACHINE LEARNING



DOI: http://dx.doi.org/10.6036/6940 | Recibido: 22/07/2013 • Aceptado: 11/12/2013

Iker Pastor-López, Jorge de-Ia-Peña-Sordo, Sendoa Rojas, Igor Santos, Pablo G. Bringas

UNIVERSIDAD DE DEUSTO. DeustoTech Computing. Avda. Las universidades, 24 – 48007 Bilbao. Tfno: +34 944 139000 iker. pastor@deusto.es

ABSTRACT

- Foundry is an important industry that supplies key castings to other industries where they are critical. Hence, iron castings1 are subject to very strict controls to assure the quality of the manufactured castings. One of the type of flaws that may appear in the castings are defects on the surface; in particular, our work focuses in inclusions, cold laps and misruns. We propose a new approach that detects imperfections on the surface using a segmentation method that marks the regions of the casting that may be affected by some of these defects and, then, applies machine-learning techniques to classify the regions in correct or in the different types of faults. We show that this method obtains high precision rates.
- Keywords: machine vision, machine learning, defect categorisation.

RESUMEN

La fundición de hierro² es una importante industria que suministra piezas clave a otras industrias donde son críticas. Es por este motivo, que las piezas fabricadas están sujetas a controles de seguridad muy estrictos para garantizar la calidad de las mismas. Algunos de los defectos que se producen con una mayor frecuencia son los superficiales, y en particular, este trabajo se centra en las inclusiones, uniones frías y las faltas de llenado. Para ello se propone un nuevo método que se basa en un algoritmo de segmentación para marcar las regiones de la superficie potencialmente defectuosas y, a continuación, aplicando técnicas de aprendizaje automático categoriza las regiones indicando el defecto existente. El método propuesto demuestra unas tasas altas de precisión.

Palabras clave: visión artificial, aprendizaje automático, categorización de defectos.

1. INTRODUCCIÓN

La fundición es uno de los procesos más antiguos en la historia de la humanidad y ha servido como indicador de referencia del progreso de la sociedad. Generalmente, consiste en fundir un material y verterlo en un molde, en el que se enfriará adquiriendo la forma deseada. Las piezas obtenidas a partir de este proceso se emplean como componentes de otros sectores clave como por ejemplo, la industria aeronáutica, la automovilística, la armamentística o la naval, entre otras. En muchos de estos casos, las piezas fabricadas juegan un papel crítico, lo que implica que deben ser objeto de numerosos controles para asegurar, de esta forma, la calidad de las piezas producidas.

Existe una gran variedad de defectos que pueden aparecer en las piezas de fundición. Este trabajo se centra en los que aparecen en la superficie de las piezas. Más concretamente, los defectos que se han seleccionado para su estudio son:

• **Inclusiones**: originadas por la incorporación de algún material no metálico a la pieza en alguna de las etapas del proceso de fundición. Este material suele ser arena del molde o escoria.

¹ Iron castings are iron-carbon alloys that solidify as laminar or nodular graphitic structures.

² Entendemos por fundición de hierro las aleaciones hierro-carbono que solidifican con estructuras grafíticas laminares o esferoidales.

- Uniones frías: ocurren cuando la temperatura de la colada es baja y la solidificación de la pieza se realiza en distintos tiempos.
- Faltas de llenado: provocadas por una falta de material fundido en el molde.

Actualmente la inspección de la calidad superficial de las piezas de fundición se realiza de forma manual por operarios, ya que son capaces de realizar esta tarea de una forma más eficaz que un sistema automatizado[1], debido principalmente a su capacidad de visión y manejo de las manos para inspeccionar las piezas desde todos los puntos de vista posibles. Por contra, según pasan las horas de trabajo, el operario va incrementando su fatiga y su capacidad de detectar defectos mengua de forma considerable.

En este sentido, la visión artificial se ha convertido en un campo importante dentro de la inspección de calidad en los procesos productivos, sobre todo en aquellos que implican un peligro o son críticos[2]. En concreto los sistemas de visión artificial están sustituyendo a los operarios en distintas industrias como por ejemplo, la maderera[3], la textil[4] o la metalúrgica [5][6]. En estos casos los sistemas implantados se han caracterizado principalmente por una disminución de errores en el proceso de inspección, inherentes al factor humano de los operarios.

En resumen, las contribuciones realizadas son: (i) la adaptación de un sistema de visión artificial y aplicación de un método de segmentación para la captura de información de las zonas de interés de las superfícies de las piezas de fundición, (ii) un enfoque basado en aprendizaje automático para la categorización de las regiones superficiales defectuosas y (iii) una validación empírica del enfoque presentado empleando para ello piezas de fundición reales.

2. EL PROCESO DE FUNDICIÓN

Aunque todos los procesos de fundición son distintos entre sí, podemos establecer una serie de etapas comunes, véase la Fig. (1). [7].

En nuestro caso nos centraremos en una fundición de hierro como caso de uso:



Fig. 1: Vista general de una planta de fundición

- Moldeo: en este punto se prepara el molde. Para ello, es necesario que la arena se encuentre en óptimas condiciones antes de ser prensada y troquelada con la forma de la pieza a alojar en su interior. En caso de la pieza disponga de huecos en su interior, es necesario añadir machos. Un molde consta de dos mitades que son unidas de forma horizontal o vertical, dependiendo de la técnica de moldeo empleada.
- Fusión: se prepara el metal para ser vertido a los moldes previamente preparados. Éste, dependiendo de las características finales de la pieza, tendrá una composición química determinada.
- **Colada**: se trata del punto dónde se vierte el metal en el molde, ya sea de manera manual o automática. Es un punto crítico donde pueden aparecer los primeros defectos.
- Enfriamiento: es otro de los puntos críticos donde se va reduciendo la temperatura de la pieza desde aproximadamente los 1300 °C hasta los 650 °C. Aquí pueden aparecer la mayoría de defectos ya sea por la reacción molde-metal, mala composición química, enfriamiento brusco, etc.
- **Desmoldeo**: los moldes continúan su enfriamiento y de manera paralela se van rompiendo separando, así las piezas de la arena. Posteriormente, las piezas son limpiadas mediante granallado para seguidamente pasar a verificación.
- Verificación: antes de verificar las piezas, como generalmente se realizan varias en un mismo molde, éstas son separadas. En este punto un operario examina las piezas y retira las que son defectuosas.

3. SISTEMA DE VISIÓN ARTIFICIAL PARA LA CAPTURA DE LA INFORMACIÓN

Para la captura de la información se ha construido un sistema de visión artificial básico, que devuelve la información de las superficies de las piezas a escanear. Este sistema está compuesto por una cámara láser con tecnología 3D, una estación de trabajo con alta capacidad de procesamiento y un brazo robótico[8].

3.1. ELEMENTOS DEL SISTEMA DE VISIÓN ARTIFICIAL

Como ya se ha mencionado anteriormente, el sistema de visión artificial construido se compone de tres elementos principales:

• Dispositivo de captura: como dispositivo de captura se ha recurrido a una cámara con tecnología láser para la captura de la información tridimensional de las piezas. Este tipo de dispositivos se caracterizan por ser menos sensibles a las condiciones de iluminación del entorno de trabajo, adaptándose de una forma más adecuada a una planta de fundición. La cámara que se ha seleccionado posee un dispositivo láser de clase 3B, debido principalmente a que el entorno dónde se quiere instalar el sistema es oscuro y es necesaria una potencia extra para observar las piezas oscuras que provocan una menor reflexión del haz láser.

- Equipo de procesamiento: se ha utilizado una estación de trabajo con una alta capacidad de cómputo compuesto por: (i) un procesador XENON E5506, (ii) 6GB de memoria RAM y (iii) una tarjeta gráfica QUADRO FX1800. Este dispositivo se encarga no sólo del control de la cámara y del brazo robótico, sino también de procesar toda la información que el dispositivo de captura va recogiendo.
- Brazo robótico: este dispositivo es el encargado de realizar los movimientos necesarios para la captura de la información. Existen dos configuraciones diferentes dependiendo del uso que se le quiera dar[9]: (i) en la primera configuración se ensambla el dispositivo de captura en el extremo del brazo robótico, mientras que por el contrario en la segunda (ii), se utiliza el brazo para manipular la pieza a escanear. Debido principalmente a que la naturaleza geométrica de las piezas que se va a manejar es muy heterogénea, se ha optado por la primera configuración, ya que de esta forma no se tiene que utilizar un utillaje distinto para cada tipo de pieza.



Fig. 2: Prototipo del sistema de visión artificial propuesto y detalle del molde

El posicionamiento de la pieza se realiza de forma manual, empleando para ello una mesa de trabajo y un soporte en el que se encaja la pieza. Este molde está fabricado a base de un material similar a la silicona, por lo que es muy maleable. En caso de que se quiera cambiar de modelo de pieza, se tendría que cambiar este molde por uno que se ajuste al nuevo modelo. Con esta mesa de trabajo y el molde se consigue escanear siempre las piezas en la misma posición, lo cual reduce la complejidad del sistema.

3.2. PROCESADO DE LA INFORMACIÓN

Empleando la arquitectura propuesta se obtiene la información superficial de las piezas. El proceso comienza con un movimiento lineal del brazo robótico, permitiendo que la cámara realice una captura cada 0.2 mm (este dato se corresponde con el grosor de la línea capturada y viene fijado por el fabricante del dispositivo de captura). De esta forma se ira recogiendo los datos con las diferentes alturas de forma consecutiva. A partir de este punto se denominara cada línea de datos obtenida con el nombre de perfil. Por lo que formalmente se puede afirmar que una superficie escaneada S está formada por un conjunto de perfiles P siendo

Uniendo estos perfiles se genera la matriz de alturas A_{nxm} (donde *n* es el número de perfiles y *m* es el número de alturas distintas que existen en cada perfil) que representa la información de la superficie *S*. De esta matriz se elimina toda la información relativa a la mesa estableciendo un umbral a partir del cual se establecerá como el nuevo 0.

Posteriormente se crean varias representaciones de la información con las que se van a ir trabajando. Estas son: (i) la matriz de alturas, (ii) la matriz de vectores normales y (iii) el mapa de vectores normales codificado en RGB.

3.2.1. Matriz de alturas

La matriz de alturas es la representación que se ha creado mediante el proceso de captura. En ella se encuentran los valores de las alturas en cada uno de los puntos de la superficie respecto al origen de coordenadas establecido en la mesa de trabajo.



Fig. 3: Visualización de la matriz de alturas mediante el renderizado de una malla 3D

3.2.2. Matriz de vectores normales

En informática gráfica, un vector normal es aquel que determina la orientación de una superficie triangular. Este vector es un elemento esencial a la hora de optimizar el proceso de dibujado de superficies, ya que contiene una gran cantidad de información sobre la superficie.



Fig. 4: Ejemplo de promediado de los vectores normales

En la Fig. (4) se puede observar en la primera de las imágenes los vectores normales para cada uno de los triángulos de la superficie. Posteriormente, para calcular el vector normal en cada uno de los puntos de la matriz de alturas, se promedia los valores de los vectores normales de los triángulos adyacentes a cada punto.

De esta forma se obtiene una matriz con la información de las componentes del vector normal en cada punto.

3.2.3. Mapa de vectores normales codificado en RGB¹

Para representar la información de la matriz de vectores normales, se ha generado una imagen que representa los distintos componentes de los vectores normales mediante los canales RGB de la imagen.

Esta imagen se genera transformando cada uno de los valores para las 3 componentes de la matriz, a su valor correspondiente en un rango cuyo valor mínimo es 0 y el máximo es 255. Posteriormente, se crea una imagen con las mismas dimensiones que la matriz de vectores normales, y se asigna los valores transformados, correspondiendo la componente Xal valor del color rojo, la Y al valor del color verde y la Z al valor del color azul.



Fig. 5: Mapa de vectores normales codificados en RGB

3.3. SEGMENTACIÓN DE LOS DATOS

El primer paso que realiza el sistema es segmentar las imágenes para identificar posibles regiones potencialmente defectuosas.

A continuación se describe los pasos en los que se divide este proceso.

- 1. Subproceso para cada una de las piezas sin indicaciones de defecto que vamos a emplear como modelos.
 - a. Se convierte el mapa de vectores normales codificado en RGB en una imagen en escala de grises. El principal motivo de este paso es disminuir el gran volumen de ruido que presenta una imagen en color.
- 2. Subproceso para cada una de las piezas con indicaciones de defecto.
 - a. Se convierte el mapa de vectores normales codificado en RGB en una imagen en escala de grises. El principal motivo de este paso es disminuir el gran volumen de ruido que presenta una imagen en color.

1 2 3 2	1
2 4 5 4	2
3 5 6 5	3
2 4 5 4	2
1 2 3 2	1

Fig. 6: Matriz de convolución del filtro de difuminado simple empleado.

- b. Se aplica al resultado del paso anterior un filtro de difuminado simple[10] para continuar con la eliminación de ruido.
- c. Se aplica un filtro de imagen que calcula la diferencia píxel a píxel entre el resultado del paso anterior y cada uno de los modelos procesados. De esta forma se obtiene aquellas regiones de la imagen que presentan diferencias con respecto a cada uno de los modelos.
- d. En este paso se agrupa la información de todas las imágenes de diferencia que se han obtenido del paso anterior. Para ello, se aplica la intersección píxel a píxel de todas ellas obteniendo una única imagen. La finalidad de esta intersección es la de agrupar en una única imagen las diferencias comunes entre la imagen de la pieza defectuosa y cada uno de los modelos.
- e. Una vez obtenida la intersección de las diferencias, se binariza (se convierte cada pixel a dos colores, blanco o negro, empleando un umbral de valor "1") destacando de esta forma las regiones que son susceptibles de tener un defecto.
- f. Finalmente, se extrae porcada una de las regiones que han sido marcadas como consecuencia del proceso realizado, el rectángulo mínimo que las contiene, eliminando aquellas que tienen un tamaño muy pequeño. En este caso se ha establecido el umbral a 3 píxeles de ancho por 3 de alto.

Como resultado del proceso de segmentación, se ha obtenido un conjunto de regiones entre las que se encuentran partes de la superficie que presentan diferencias tolerables con respecto a los modelos, así como partes de la pieza con defectos que provocan el rechazo de la misma.



Fig. 7: Imagen binarizada obtenida mediante el método de segmentación descrito. En ella, podemos ver señaladas en rojo tres regiones con indicaciones de defecto

³ Siglas en inglés de los colores Rojo, Verde y Azul (Red, Green y Blue). Es un modelo de color con el que es posible representar un color mediante la mezcla por adición de los tres colores primarios.

3.4. CARACTERÍSTICAS EXTRAÍDAS

A continuación, se agrupan las distintas características que se han extraído en base a su representación de origen.

• Características extraídas de la imagen binarizada resultado del método de segmentación. Esta imagen se ha obtenido del proceso de segmentación y se encuentra binarizada. De esta forma se tiene marcado en color blanco la porción de la región marcada como potencialmente defectuosa, y en negro el resto del segmento.

Las características son:

- Alto, ancho, perímetro y área de la porción de píxeles blancos contenida en la región.
- Distancia euclidiana entre el centro de gravedad de la región y el origen de coordenadas.
- Plenitud⁴ de la región.
- Características extraídas de la imagen binarizada convertida a imagen integral. La imagen integral *I* de una imagen *G* se define como la imagen en la que la intensidad de un pixel en una posición determinada es igual a la suma de las intensidades de todos los píxeles que hay encima y a la izquierda de la posición dada en la imagen original *G* [11]. En concreto, las características que hemos extraído son:
 - Media de los valores de los píxeles de la imagen integral.
 - Sumatorio de los valores de los píxeles de la imagen integral.
- Características extraídas de la matriz de alturas. En este caso se extraen dos regiones distintas. En la primera de ellas, se obtiene todos los píxeles de la matriz de alturas para la región extraída mediante el proceso de segmentación. En el segundo, se quedan únicamente con aquellos píxeles que hayan sido marcados en blanco en el segmento obtenido mediante el método de segmentación. Posteriormente, se extraen las siguientes características:
 - Sumatorio, media, varianza, desviación estándar, error estándar, mínimo, máximo, rango, mediana, entropía, sesgo y curtosis de las alturas de la región.
- Características extraídas de las matrices de vectores normales. Se extraen las regiones correspondientes a la zona delimitada por el método de segmentación. Como se ha especificado anteriormente, cada una de las matrices hace referencia a las componentes del vector normal en cada punto (x, y, z). Además, como en el caso anterior, se extrae por cada matriz dos regiones distintas, una obteniendo todos los valores, y otra con los valores marcados en blanco por el método de segmentación. Posteriormente, se extraen las siguientes características:
 - Sumatorio, media, varianza, desviación estándar, error estándar, mínimo, máximo, rango, mediana, entropía, sesgo y curtosis de cada una de las componentes de los vectores normales de la matriz.

4. ALGORITMOS DE APRENDIZAJE AUTOMÁTICO SUPERVISADO

El aprendizaje automático es un área activa de investigación dentro de la Inteligencia Artificial, que se centra en el diseño y desarrollo de nuevos algoritmos que permiten a los ordenadores razonar y decidir sobre un conjunto de datos conocido[12].

Los algoritmos de aprendizaje automático pueden dividirse en tres tipos diferentes, dependiendo del conjunto de datos de entrenamiento: (i) aprendizaje supervisado, (ii) aprendizaje no supervisado y (iii) aprendizaje semi-supervisado. Para los algoritmos de aprendizaje supervisado, el conjunto de datos de entrenamiento tiene que estar etiquetado (p. ej., el defecto en la pieza)[13]. Los algoritmos de aprendizaje no supervisado intentan determinar cómo se pueden organizar los datos en diferentes conjuntos o grupos, por lo que no es necesario etiquetar⁵ los datos[14]. Finalmente, los algoritmos semi-supervisados usan una combinación de datos etiquetados y no etiquetados para construir los modelos, mejorando de forma exclusiva la precisión obtenida por los métodos no supervisados[15].

Debido a que las regiones extraídas de las piezas pueden se pueden etiquetar, se han utilizado algoritmos de aprendizaje automático supervisados. A continuación, se describen los algoritmos empleados.

4.1. REDES BAYESIANAS

Las redes bayesianas, las cuales están basadas en el teorema de **Bayes**, se definen como un modelo gráfico probabilístico para el análisis multivariable. Específicamente, son grafos acíclicos directos que tienen asociada una función de distribución de probabilidad[16]. Los nodos del grafo representan variables del problema (que pueden ser una premisa o conclusión) y las aristas representan las dependencias condicionales entre dichas variables.

La ventaja principal de las redes bayesianas es su capacidad para determinar la probabilidad de que una hipótesis sea verdadera, dado un conjunto de datos.

4.2. ÁRBOLES DE DECISIÓN

Los árboles de decisión son un tipo de clasificador dentro del aprendizaje automático supervisado que puede representarse gráficamente con forma de árbol. Los nodos internos representan condiciones con respecto a las variables del problema, mientras que por el contrario, las hojas o nodos finales representan la decisión del algoritmo[17].

Existen distintos métodos de aprendizaje dentro de los árboles de decisión entre los que destacan los bosques aleatorios, un conjunto de diferentes árboles de decisión creados aleatoriamente[18] y, J48 la implementación en WEKA[19] del algoritmo C4.5[20].

⁴ Se define como el número de píxeles blancos dividido por el número de píxeles totales de la región.

⁵ Se basa en clasificar de forma manual el tipo de indicación de defecto que presenta la región.

4.3. K VECINOS MÁS PRÓXIMOS

El clasificador *K* vecinos más próximos o KNN (*K Nearest Neighbours*)[21] es uno de los modelos más simples de aprendizaje automático supervisado. Este método clasifica una muestra desconocida basándose en la clase de las instancias más próximas a ella en el espacio de entrenamiento.

4.4. MÁQUINAS DE SOPORTE VECTORIAL

Los algoritmos basados en máquinas de soporte vectorial o SVM (*Support Vector Machines*) dividen la representación *n*-dimensional del espacio de datos en dos regiones empleando para ello un hiperplano. Este hiperplano siempre maximiza el margen entre estas dos regiones o clases. Este margen se define como la distancia más lejana entre las muestras de dos clases y se calcula en base a la distancia entre los elementos más cercanos de las dos clases, que se denominan vector de soporte[22].

Por último, estos clasificadores emplean las denominadas funciones del núcleo, que les permiten crear divisiones no lineales, como superficies polinómicas, radiales o sigmoideas[23].

5. VALIDACIÓN DEL MÉTODO DESARROLLADO 5.1. DESCRIPCIÓN DE LA METODOLOGÍA DE VALIDACIÓN

Los experimentos se han centrado en 3 defectos superficiales: las inclusiones, las uniones frías y las faltas de llenado. En cuanto a la pieza empleada, se trata de una pieza circular con un diámetro de 87mm. y una altura de 43mm. Está producida mediante moldeo vertical con hierro grafítico-esferoidal y se usa en la construcción de vehículos industriales.

Se ha comenzado el experimento capturando la información de cada una de las superficies de un total 639 piezas distintas. Entre ellas se han identificado 236 ejemplares totalmente correctos, esto es que han pasado los procesos de calidad manuales correspondientes; y 403 piezas que presentan una o más indicaciones de defecto superficial.

Posteriormente, se han aplicado el proceso descrito en las secciones 3.2 y 3.3 obteniendo 6.150 regiones potencialmente defectuosas. Concretamente, se tiene la siguiente distribución de regiones: 5,686 tolerables, 392 con inclusión, 17 con unión fría y 55 con falta de llenado.

Una de las primeras conclusiones a tener en cuenta al ver el conjunto de datos es que no se encuentra balanceado, debido principalmente a que en un entorno real son más probables las regiones correctas que las que presentan algún defecto. Por este motivo, se ha aplicado una técnica de re-sampleo sintético minoritario o SMOTE por sus siglas en inglés (*Synthetic Minority Over-sampling TEchnique*)[24]. Ésta, se basa en generar muestras sintéticas de las clases que tienen un número menor de elementos, balanceando de esta forma el conjunto de datos de entrenamiento.

La clasificación de las regiones defectuosas se ha realizado de forma manual por un operario especializado, basándose en los criterios de aceptación establecidos por el cliente. Hay que tener en cuenta que estos criterios son muy estrictos debido principalmente a que la industria de la automoción establece unos estándares de calidad muy altos. La primera evaluación que se ha realizado es del método de segmentación de regiones potencialmente defectuosas. Para ello se ha calculado la *Cobertura* del mismo:

$$Cobertura = \frac{SDE}{SDE + SDNE} *100 \tag{1}$$

donde *SDE* es el número de segmentos defectuosos encontrados, y *SDNE* es el número de segmentos defectuosos no encontrados. Este valor de cobertura se utiliza para medir la fiabilidad de la detección de regiones con indicación de defecto.

La segunda evaluación que se realiza es la precisión del método basado en aprendizaje automático.

Para ello, se ha seguido la siguiente metodología de experimentación:

- Validación cruzada: este método se basa en la división del conjunto de regiones en *K* subconjuntos distintos[25], empleándose una parte de cada uno de estos *K* subconjuntos para entrenar el modelo y la otra para probarlo. En nuestro caso concreto, se ha asignado a la *K* el valor 10, con lo que se ha dividido el conjunto de regiones con indicación de defecto en 10 subconjuntos distintos. En cada uno de estos subconjuntos se han empleado el 90% para entrenar el modelo y el 10% restante para probarlo.
- SMOTE: para cada uno de los subconjuntos de entrenamiento generados mediante la validación cruzada, se aplica la técnica de SMOTE, consiguiendo de esta forma que estos subconjuntos de entrenamiento estén balanceados.
- Generación de los modelos: para cada subconjunto de entrenamiento hemos generado un modelo basado en distintos algoritmos de aprendizaje automático supervisado. En concreto, se han empleado los siguientes algoritmos:
 - **Redes bayesianas**: dentro de los algoritmos basados en el teorema de Bayes, se ha utilizado distintos tipos: red bayesiana ingenua[25], red bayesiana con K2[26] y red bayesiana ingenua aumentada con árbol[27].
 - Máquinas de soporte vectorial (SVM): para este clasificador se han empleado distintos núcleos: el polinomial[23], el normalizado polinomial[28], el Pearson VII[29] y el de función de base radial o RBF[30].
 - K-vecinos más próximos: se ha realizado el experimento con los siguientes valores para *K*: 1, 2, 3, 4 y 5.
 - Árboles de decisión: los algoritmos empleados basados en árboles de decisión son: J48, que se trata de la implementación para la herramienta WEKA[19] del algoritmo C4.5[20]; y bosques aleatorios[18], para los que hemos definido distintas configuraciones en base al número de árboles aleatorios a generar N: 10, 25, 50, 75 y 100.

Para evaluar los resultados obtenidos de los modelos generados, se ha basado en la precisión o porcentaje de instancias clasificadas correctamente y en el área bajo la curva ROC, que representa la relación entre la tasa de falsos negativos y la de falsos positivos[31].

5.2. RESULTADOS OBTENIDOS

En primer lugar se va a evaluar la validez del método de segmentación, para lo que se calcula la cobertura del mismo.



Fig. 8: Porcentaje de acierto de los clasificadores empleados





Fig. 9: Resultados en términos de área bajo la curva ROC obtenidos con los diferentes algoritmos de aprendizaje automático empleados

6. CONCLUSIONES

En este artículo se ha propuesto un nuevo sistema basado en visión artificial y aprendizaje automático con el fin de detectar y categorizar defectos en las superficies de piezas de fundición de hierro nodular. Este enfoque empieza recuperando la información superficial de las piezas y generando distintas representaciones de la misma. Posteriormente, se propone un método de segmentación para determinar regiones potencialmente defectuosas. Finalmente, se categoriza las regiones en base a modelos de aprendizaje automático.

Se ha evaluado nuestro enfoque en términos de cobertura para el método de segmentación y, en base a la precisión y área bajo la curva ROC para la categorización de las regiones. Los resultados experimentales muestran una precisión alta en cuanto a la categorización de defectos.

El trabajo futuro está orientado hacía dos líneas de trabajo principalmente. En la primera de ellas,

En este caso el sistema ha sido capaz de detectar el 59,70% de los defectos. Se quiere destacar que el resto de defectos presentes en las superficies escaneadas, se encuentran en zonas con bordes; los cuales, serían detectados realizando otros movimientos de escaneo complementarios. Aun así, una de las futuras mejoras es incrementar la cobertura del método de segmentación desarrollado, teniendo en cuenta que este porcentaje puede variar dependiendo de la geometría de la pieza con la que se está trabajando.

Como se puede observar en las gráficas de la Fig.(8) y Fig.(9), los mejores resultados son los obtenidos por los bosques aleatorios de más de 50 árboles y por la máquina de soporte vectorial con un núcleo *Pearson VII*. En ambos casos la precisión supera el 95% y el área bajo la curva ROC es ligeramente superior a 0,97.

En cuanto al resto de clasificadores empleados, se observa que de entre los bayesianos únicamente son destacables los resultados obtenidos por la red bayesiana aumentada con árbol, con más de un 95% de precisión, y un área bajo la curca ROC superior a 0,90 En el caso de los KNN ninguna de las configuraciones probadas arroja unos resultados satisfactorios. trabajar en la mejora de la cobertura, modificando el método de segmentación. En la segunda línea, buscar incrementar la precisión en la categorización de regiones, para lo que investigaremos el uso de nuevos tipos de características así como la aplicación de nuevos métodos de aprendizaje para la disminución del esfuerzo de etiquetado.

AGRADECIMIENTOS

Este trabajo ha sido parcialmente apoyado por el Ministerio de Ciencia e Innovación de España bajo el programa "Proyectos Singulares y Estratégicos del Programa Nacional de Cooperación Público-Privada 2009", proyecto "POLIFEMO: POlifemo, Lowering Imperfections in Foundry Enterprise via a Machine-vision Oriented model" (en castellano, Polifemo, Reduciendo las Imperfección en la empresa de fundición a través de un modelo orientado a la visión artificial), proyecto "CIT-020000-2009-008. Por último, se quiere agradecer al centro de investigación metalúrgica IK4-AZTERLAN por su colaboración en el proyecto.

BIBLIOGRAFÍA

- A. Mital, M. Govindaraju, and B. Subramani. "A comparison between manual and hybrid methods in parts inspection," Integrated Manufacturing Systems. 1998, vol. 9. no. 6. pp. 344–349. (doi: http://dx.doi. org/10.1108/09576069810238709).
- P. Kopardekar, A. Mital, and S. Anand. "Manual, hybrid and automated inspection literature and current research," Integrated Manufacturing Systems. 1993. vol. 4. no. 1. pp. 18–29. (doi: http://dx.doi.org/10.1108/09576069310023838).
- [3] O. Silvén, M. Niskanen, and H. Kauppinen. "Wood inspection with non-supervised clustering". Machine Vision and Applications. 2003. vol. 13. no. 5. pp. 275–285. (doi: http://dx.doi. org/10.1007/s00138-002-0084-z).
- [4] V. Murino, M. Bicego, and I. Rossi. "Statistical classification of raw textile defects". Proceedings of the 17th International Conference on. vol. 4. pp. 311– 314. (doi: http://dx.doi. org/10.1109/ICPR.2004.1333765).
- [5] F. Pernkopf. "Detection of surface defects on raw steel blocks using bayesian network classifiers". Pattern Analysis & Applications. 2004. vol. 7. no. 3. pp. 333–342. (doi: http://dx.doi. org/10.1007/s10044-004-0232-3).
- [6] Y. Frayman, H. Zheng, and S. Nahavandi. "Machine vision system for automatic inspection of surface defects in aluminum die casting". Journal of advanced computational intelligence. 2005. vol. 10. no. 3. pp. 281–286.
- [7] S. Kalpakjian and S. Schmid. Manufacturing engineering and technology. 2005.
- [8] F. Pernkopf and P. O'Leary. "Image acquisition techniques for automatic visual inspection of metallic surfaces". NDT & E International. 2003. vol. 36. no. 8. pp. 609–617. (doi: http:// dx.doi.org/10.1016/S0963-8695(03)00081-1).
- [9] D. vom Stein. "Automatic visual 3-d inspection of castings". Foundry Trade Journal. 2007. vol. 180. no. 3641. pp. 24–27.
- [10] R. Gonzalez and R. Woods. "Digital image processing". 1992. Reading, Mass.: Addison-Wesley. vol. 16. no. 716. p. 8.
- [11] P. Viola and M. Jones. "Robust real-time face detection". International journal of computer vision. 2004. vol. 57. no. 2. pp. 137–154. (doi: http://dx.doi.org/10.1023/B:VISI.0000013087.49260.fb).
- [12] C. Bishop. Pattern recognition and machine learning. Springer New York. 2006.
- [13] S. Kotsiantis. "Supervised Machine Learning: A Review of Classification Techniques". in Proceeding of the 2007 conference on Emerging Artificial Intelligence Applications in Computer Engineering: Real Word AI Systems with Applications in eHealth, HCI, Information Retrieval and Pervasive Technologies. 2007. pp. 3–24.
- [14] S. Kotsiantis and P. Pintelas. "Recent advances in clustering: A brief survey". WSEAS Transactions on Information Science and Applications. 2004. vol. 1. no. 1. pp. 73–81.
- [15] O. Chapelle, B. Schölkopf, and A. Zien, Semi-supervised learning. 2006. MIT Press.
- [16] E. Castillo, J. M. Gutiérrez, and A. S. Hadi. Expert Systems and Probabilistic Network Models. 1996. erste ed.. New York. NY. USA.
- [17] J. Quinlan. "Induction of decision trees". Machine learning. 1986. vol. 1. no. 1. pp. 81–106. (doi: http://dx.doi. org/10.1023/A:1022643204877).

- [18] L. Breiman. "Random forests". Machine learning. 2001. vol. 45. no. 1. pp.5–32. (doi: http://dx.doi. org/10.1023/A:1010933404324).
- [19] S. Garner. "Weka: The Waikato environment for knowledge analysis". in Proceedings of the 1995 New Zealand Computer Science Research Students Conference. 1995. pp. 57–64.
- [20] J. Quinlan. C4. 5 programs for machine learning. 1993. Morgan Kaufmann Publishers.
- [21] E. Fix and J. L. Hodges. "Discriminatory analysis: Nonparametric discrimination: Small sample performance". Technical Report Project. 1952. 21-49-004, Report Number 11.
- [22] V. Vapnik. The nature of statistical learning theory. Springer. 2000.
- [23] S. Amari and S. Wu. "Improving support vector machine classifiers by modifying kernel functions". Neural Networks. 1999. vol. 12. no. 6. pp. 783–789. (doi: http://dx.doi. org/10.1016/S0893-6080(99)00032-5).
- [24] N. Chawla, K. Bowyer, L. Hall, and W. Kegelmeyer. "SMOTE: synthetic minority over-sampling technique". Journal of Artificial Intelligence Research. 2002. vol. 16. no. 3. pp. 321–357. (doi: http://dx.doi.org/10.1613/jair.953).
- [25] C. M. Bishop. Neural Networks for Pattern Recognition. Oxford University Press. 1995.
- [26] G. F. Cooper and E. Herskovits. "A bayesian method for constructing bayesian belief networks from databases". in Proceedings of the 1991 conference on Uncertainty in artificial intelligence, 1991.
- [27] D. Geiger, M. Goldszmidt, G. Provan, et al. "Bayesian network classifiers" in Machine Learning. 1997. pp. 131–163. (doi: http://dx.doi.org/10.1023/A:1007465528199).
- [28] S. Maji, A. Berg, and J. Malik. "Classification using intersection kernel support vector machines is efficient". in Proc. CVPR. 2008. vol. 1. no. 2. p. 4. (doi: http://dx.doi.org/10.1109/ CVPR.2008.4587630).
- [29] B. U" stu"n, W. Melssen, and L. Buydens. "Visualisation and interpretation of support vector regression models". Analytica chimica acta. 2007. vol. 595. no. 1–2. pp. 299–309. (doi: http://dx.doi.org/10.1016/j.aca.2007.03.023).
- [30] B. Cho, H. Yu, J. Lee, et al. "Nonlinear support vector machine visualization for risk factor analysis using nomograms and localized radial basis function kernels". IEEE Transactions on Information Technology in Biomedicine. 2008. vol. 12. no. 2. p. 247. (doi: http://dx.doi.org/10.1109/TITB.2007.902300).
- [31] Y. Singh, A. Kaur, and R. Malhotra. "Comparative analysis of regression and machine learning methods for predicting fault proneness models". International Journal of Computer Applications in Technology. 2009. vol. 35. no. 2. pp. 183–193. (doi: http://dx.doi.org/10.1504/IJCAT.2009.026595).