

AUTOMATIZACIÓN DE LA INSPECCIÓN DE SUPERFICIES ACABADAS MEDIANTE ALGORITMOS INNOVADORES DE VISIÓN ARTIFICIAL

VAMAD

Visión artificial

El proyecto VAMAD, impulsado por AIDIMA (Instituto Tecnológico del Mueble, Madera, Embalaje y Afines), está desarrollando algoritmos innovadores de visión artificial para la industria del mueble y afines. La tecnología permitirá detectar de forma más precisa los defectos en los acabados superficiales.

El proyecto VAMAD (Visión Artificial aplicada a la Madera) pertenece al programa Consorcio (Fomento de la investigación técnica para proyectos consorciados) del Ministerio de Industria, Turismo y Comercio. Es un proyecto de visión artificial avanzada orientada al sector de la madera y afines (rechapadores, fabricantes de tableros acabados, fabricantes de mobiliario, etc.). En el proyecto participan AIDIMA, CETEM (Centro Tecnológico de la Madera de la Región de Murcia), AIDO (Instituto Tecnológico de Óptica, Color e Imagen) y AIN (Asociación de la Industria Navarra). VAMAD fue uno de los 6 proyectos consorciados aprobados por el Ministerio en 2007, de un total de 32 presentados. AIDIMA es el centro coordinador e impulsor del proyecto. Éste, de tres años de duración, tiene un coste previsto de 1,57 millones de euros, y está financiado al 50% por el programa Consorcio. La página electrónica elaborada para el proyecto es <http://www.aidima.es/vamad/>.

La motivación para este proyecto nace de la necesidad de la industria del mueble y afines de evitar la aparición de defectos durante los procesos de acabado (pintado, barnizado, lacado, aplicación de lasures, revestimiento de tableros con melaminas, con papel termofusible, con chapas, etc.). Algunos de estos defectos son cráteres, burbujas, arrugas, cuarteamientos, descuelgues, escamas, goteos, velados, centelleos, caleos, escarchados, amarilleos, piel de naranja, agrisado de poros, etc. Según un estudio de AIDIMA, los defectos de acabado causan el 80% de las reclamaciones en el sector del mueble y pérdidas equivalentes al 15-20% del coste de las materias primas. Como estos defectos son detectados muchas veces por el usuario final, aumentan los costes asociados a devoluciones y reemplazos de los muebles. Una detección temprana de los defectos en la línea de producción mejorará la calidad de los productos (muebles, parquetes, chapas, tableros), evitará que el defecto se propague y reducirá los costes de sustitución y reparación.

Dentro del proyecto VAMAD, el Departamento de Tecnología y Biotecnología de la Madera de AIDIMA, realiza la implementación y adaptación industrial de métodos de detección y clasificación de defectos en los recubrimientos. Dichos métodos basados en técnicas de tratamiento digital de imágenes y reconocimiento de patrones son desarrollados por el Instituto de Tecnología Industrial de la Información (IIIT) de la Universidad de Karlsruhe. Estos algoritmos se integrarán en un sistema de adquisición de imágenes, conformando así un sistema de visión artificial de nueva gene-

ración destinado a la detección y clasificación automática de defectos en los acabados de madera y derivados.

Metodología del proyecto

El sistema de visión artificial propuesto se basa en métodos innovadores desarrollados por el Instituto (IIIT) de la Universidad de Karlsruhe. Dichos métodos integran técnicas de iluminación, de procesamiento digital de imágenes y de reconocimiento de patrones.

El principal problema al que se enfrenta la inspección automática de superficies barnizadas viene dado por sus características ópticas. Si la superficie es analizada bajo luz difusa, el contraste resulta muy bajo y los defectos son casi imperceptibles. Por otro lado, si la película de barniz se observa desde un punto fijo bajo luz direccional, la infor-




Figura 1. Variación del ángulo de iluminación durante la adquisición de imágenes.

mación que se percibe depende de la dirección de iluminación utilizada. Para un punto fijo de observación, la superficie presenta una apariencia distinta para cada ángulo de iluminación diferente. Debido a esta característica, las superficies barnizadas se denominan superficies no cooperativas. Dichas superficies no pueden ser analizadas ni mucho menos clasificadas en base a una sola imagen, pues la información obtenida bajo un ángulo de iluminación es parcial e insuficiente. Resulta, entonces, necesario inspeccionar la superficie bajo diferentes ángulos de iluminación para recolectar toda la información relevante. Esto se logra mediante la generación de series de imágenes. Una serie de imágenes consiste en un conjunto de fotografías, donde cada una muestra la misma porción de superficie, pero bajo una dirección de iluminación diferente (véase la figura 1).

En el sistema de visión artificial que desarrollarán AIN, AIDO y AIDIMA, las series de imágenes se obtendrán iluminando las muestras con cuatro fuentes de luz estroboscópicas (barras de LEDs) colocadas de manera que formen un cuadrado (figura 2).




Figura 2.
Fuentes estroboscópicas para conseguir series de imágenes.

A la dificultad generada por las características no cooperativas de la superficie se suma el hecho de que el sistema de visión artificial tiene que trabajar con diferentes tipos de madera y de acabados. Esto toma particular importancia cuando los acabados son transparentes. En ese caso, el sustrato o soporte es visible y se presenta en las imágenes con una gran variedad de texturas y colores. La existencia de este fondo variable en las imágenes no debe alterar la detección y clasificación de los defectos de acabado. El sistema no debe dejarse "confundir" por la apariencia del soporte. En otras palabras: los métodos desarrollados deben ser lo más insensibles posibles a los cambios de sustrato.

Una serie de imágenes contiene la información necesaria para clasificar la superficie. Las técnicas desarrolladas procesan dicha serie como un todo, extrayendo información sobre las variaciones de intensidad producidas por los cambios en la iluminación. De cada serie de imágenes se extrae aquella información que resulta relevante para la clasificación de la superficie. Dicha información recibe el nombre de característica. Las características extraídas son el resultado de diferentes operaciones matemáticas ejecutadas sobre las series de imágenes. Por lo tanto las características están representadas por valores numéricos (vectores, matrices, etc.) que correctamente interpretados contienen información sobre los defectos en el barnizado. Consideremos un ejemplo

muy sencillo: supongamos que una característica calculada de una serie de imágenes que no muestra ningún defecto tiene el valor 0. En cambio, si la serie presenta una grieta esta misma característica toma el valor 5. El método desarrollado debe lograr que, para cualquier sustrato, el valor extraído sea cero siempre que la superficie no presente ningún defecto; y siempre que exista una grieta, el valor sea 5. Además, en el caso de existir una grieta la característica debe mantenerse en 5, independientemente de la posición de la grieta o de su ángulo de inclinación. Cuando se trabaja con características que cumplen condiciones como éstas, es decir se mantienen constantes a pesar de que las imágenes sufren ciertos cambios, nos referimos a ellas como invariantes.

En el mundo físico, encontramos a menudo características invariantes: la distancia entre dos ciudades en un mapa no cambia por mucho que rotemos o movamos el mapa. También el número de lados de un triángulo es una invariante, ya que no importa las veces que lo giremos o lo movamos: la característica siempre da 3.

Las operaciones matemáticas involucradas en la obtención de características consisten en comparar las intensidades que distintos puntos de la superficie presentan bajo diferentes direcciones de iluminación. Una posible operación consiste en seleccionar una región circular dentro de dos fotografías de la serie y comparar los valores de intensidad a lo largo del perímetro de dicha circunferencia (véase la figura 3). Esta operación permite, por ejemplo, saber si un punto de la superficie aparece muy claro para una iluminación y muy oscuro para otra, lo cual puede ser un indicio de que tal punto se encuentra en el borde de un defecto.




Figura 3.
Esquema de una posible operación matemática para el cálculo de características.

Se pueden definir muchas operaciones matemáticas para que diferentes características representen diferentes aspectos de la superficie. Si desea más información, puede consultar las referencias al final del artículo.

Una vez obtenida una invariante, debe ser interpretada o clasificada. Es decir, debe decidirse si la invariante representa un defecto en particular o no. Esto es tarea de un clasificador. En este proyecto se utiliza un sistema de aprendizaje supervisado (un Support Vector Machine o SVM) para clasificar. El término supervisado proviene del hecho de que el clasificador debe entrenarse primero. Esto requiere que, en una primera etapa, el clasificador asocie los posibles resultados de las invariantes con los defectos que representan. Siguiendo el ejemplo anterior, debe enseñarse al

clasificador que 5 significa grieta y 0 significa ningún defecto. Dada la dificultad del problema, las invariantes capaces de representar defectos del barnizado son mucho más complejas que un simple número 5 o 0, como en el ejemplo propuesto. Las invariantes utilizadas vienen representadas por matrices (figura 4). Dichas matrices resultan no sólo de operaciones matemáticas como las expuestas anteriormente, sino también de la construcción de histogramas difusos (fuzzy histograms). Éstos son poco sensibles al número de segmentos con que se clasifica y, por tanto, resultan muy estables a cambios pequeños, lo cual disminuye la sensibilidad del método al ruido.

Uno de los principales objetivos para lograr una buena clasificación de los defectos es lograr que los valores de las invariantes sean muy distintos cuando representan defectos diferentes, y muy parecidos cuando se trata del mismo defecto. En la figura 4 puede observarse que las matrices obtenidas como invariantes son muy diferentes cuando existe un defecto y cuando no.

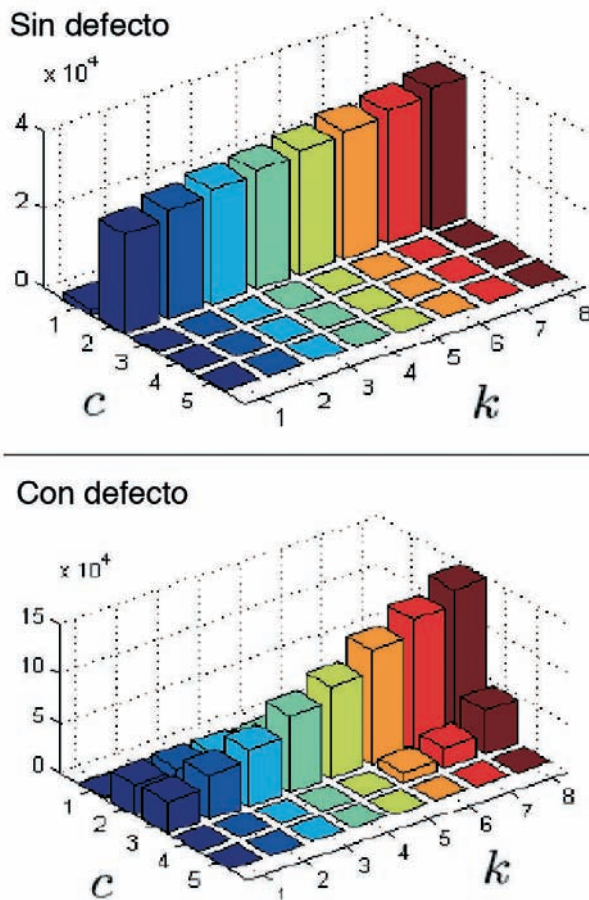


Figura 4. Comparación de invariantes obtenidas para una superficie con defecto y sin defecto.

La figura 5 muestra una grieta utilizada en el entrenamiento del SVM. Un experto ha marcado el defecto y luego se lo ha dado al clasificador para que éste establezca una asociación entre las invariantes calculadas y el defecto (grieta). Después se proporciona al clasificador una segunda imagen de una grieta para comprobar si el aprendizaje ha resultado correcto. La nueva imagen presenta una grieta en una posición diferente y sobre un sustrato diferente. La figura 6 muestra el resultado de la clasificación; se comprueba que el SVM reconoce la grieta.

Actualmente, AIDIMA e IIIT están probando estos nuevos métodos de detección con muestras de madera y materiales derivados con defectos de acabado. Muchas de ellas proceden de la de industria y son el resultado de fallos reales durante los procesos de acabado. Un grupo más reducido de las muestras se ha creado en los laboratorios de AIDIMA y de CETEM mediante, por ejemplo, métodos de aplicación erróneos o incompatibilidades entre los recubrimientos y el sustrato.




Figura 5. Marcado del defecto con la interfaz gráfica de los algoritmos. Así se informa al SVM que el defecto es una grieta.




Figura 6. Resultado de la detección de una grieta.

Por el momento, los métodos desarrollados reconocen grietas, burbujas y cráteres (varios de los tipos de defectos más frecuentes en la industria), incluso de tamaño reducido. Además, se trabaja en la extensión de estos resultados a nuevos defectos como piel de naranja, descuelgues, etc.

AIDIMA está mejorando la interfaz desarrollada por el IIIT para aumentar la velocidad de detección de los defectos en las muestras de madera y derivados y para facilitar la implantación del software en cualquier tipo de ordenador, lo cual es imprescindible para la industria. Por la relevancia de los resultados para la industria del mueble y afines, los resultados del proyecto se irán divulgando lo antes posible entre las empresas del sector.

Por **Ana Pérez Grassi y Fernando Puente León**. Instituto de Tecnología Industrial de la Información de la Universidad de Karlsruhe

Por **Efrén Crespo Navarro y Miguel Ángel Abián**. Departamento de Tecnología y Biotecnología de la Madera de AIDIMA

Referencias:

Ana Pérez Grassi, Fernando Puente León. Translation and Rotation Invariant Histogram Features for Series of Images. In INFORMATIK 2007: Informatik trifft Logistik - Beiträge der 37. Jahrestagung der Gesellschaft für Informatik, Vol. 109(11) of GI Proceedings, 2007.