

ALGORITMO PARA LA DETECCIÓN DE FALLA EN PISOS CERÁMICOS

Arroyo Hernández, Jessica (1), Ibarra Manzano, Mario Alberto (2).

1 Ingeniería en Comunicaciones y Electrónica, Universidad de Guanajuato | yeye_jessic@hotmail.com,
j.arroyohernandez@ugto.mx

2 Departamento de Ingeniería Electrónica, División de Ingenierías, Campus Irapuato- Salamanca, Universidad de Guanajuato | ibarram@ugto.mx

Resumen

Para lograr una mejora en los procesos de producción es necesario optimizar diversas técnicas y áreas, siendo una de ellas la zona de calidad. Para esto, es necesario conocer los diferentes tipos de contratiempos y fallas, y tratar de encontrar una forma de solucionarlos o contrarrestarlos. En la industria de la de fabricación de cerámicos, uno de sus principales problemas es la detección de productos con errores de fabricación. En este trabajo se desarrolla una técnica de detección de fallas cromáticas en pisos cerámicos de diferentes dimensiones, específicamente manchas negras, utilizando características estadísticas y árboles de decisión.

Abstract

To improve production processes is necessary optimize diverse areas and techniques, being quality one of them. For make this, is required to know different kind of fails and setbacks, and try to find a way to delay or solve them. In ceramic manufacturing industry, one of the main problems is detection of products with manufacturing errors. In this paper is developed a chromatic fails detection technique in ceramic floors in diverse dimensions, black spots specifically, using statistical features and decision trees.

Palabras Clave

AdaBoost; Árbol de clasificación, CIE-Lab, Procesamiento de imágenes; Optimización.

INTRODUCCIÓN

Dentro de toda producción se debe cuidar la calidad de los productos finales, esto con el objetivo de satisfacer en la medida de lo posible las expectativas del cliente, así como para garantizar el óptimo resultado de este proceso.

Para lograrlo, es necesario contar con un departamento que se especifique en la detección de elementos en mal estado, a esta área se le llama control de calidad. Dentro de una línea de producción, es vital el poder realizar este proceso sin tener la necesidad de detener o ralentizarla, puesto que esto representaría grandes pérdidas y la pérdida de optimización de la planta entera.

El poder realizar la detección de fallas de los productos de manera automática, garantiza optimizar el tiempo de producción y evita problemas posteriores. Es por esto que este trabajo se trata de desarrollar una técnica que nos ayude a la detección de un tipo específico de falla presente en la industria de los cerámicos.

Cerámicos

Los cerámicos son materiales que tienen una gran diversidad de aplicaciones, siendo el decorado de interiores una de ellas. Para este fin, se producen diferentes tipos de azulejos cerámicos con características diversas, ya sea por su grabado, textura, color, tamaño o uso.



Figura 1: Ejemplo de un cerámico blanco

Puesto que cada una de las características antes mencionadas se logra bajos diversos procesos, se pueden presentar errores relacionados a cada uno

de ellos, resultando en la aparición de fallas en los cerámicos.

Al finalizar el proceso de fabricación, cada uno de los productos es sujeto a una inspección de calidad mediante clasificación para identificar algún defecto, este control de calidad generalmente es realizado por miembros del personal de manera visual, lo cual deja el proceso propenso al error humano.

Tipos de fallas

De acuerdo a la etapa en la que se presente un fallo en la línea de producción, es el tipo de error presente en el cerámico. Un fallo podría presentarse al comienzo del proceso, que se reflejan como irregularidades geométricas (cerámico roto, bordes irregulares, arañazos, superficie cóncava o convexa, protuberancias, etc.). A la mitad o al final del proceso, un fallo puede aparecer como pequeños agujeros, grietas superficiales, irregularidades en la cobertura, defectos de alineación, fallo en el color y textura [1].




Figura 2: Ejemplo de un cerámico blanco que presenta un defecto de color

En este trabajo, se emplearan cerámicos de color blanco (figura 1) que presentan fallos en color negro como el que se muestra en la figura 2.

Color

El color no es una propiedad intrínseca de los objetos, lo que hace que un objeto sea percibido con un determinado color depende en primer lugar a la luz incidente sobre el mismo. En segundo lugar, a las propiedades químicas de la materia de la que estén formados los cuerpos y por último al sistema

visual humano que será quien determine la sensación cromática percibida por el cerebro. Es por esto último que una misma muestra de color es percibida de manera diferente por dos observadores [2].

Espacios de color

Los espacios de color proporcionan un método para especificar, ordenar y manipular colores.

Los colores se representan mediante puntos en espacios de n dimensiones. Existen numerosos espacios de color en la actualidad. La gran mayoría de ellos se han desarrollado para aplicaciones específicas, aunque todos parten de un mismo concepto: la teoría de colores primarios: rojo, verde y azul [2].

Modelo RGB

El modelo RGB basado en la teoría de colores primarios es representado por un espacio tridimensional de números positivos, cada dimensión representa la cantidad de rojo, verde y azul contenido en una muestra. Tradicionalmente, el espacio es representado en valores entre 0 y 1 lo cuales representan el blanco y en negro respectivamente, aunque existe una representación extendida que toma valores de 0 a 255, representación empleada en este desarrollo. [2]

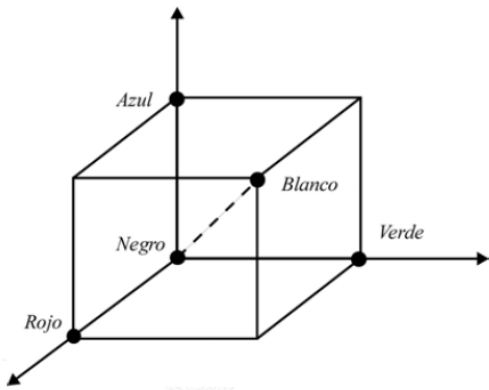


Figura 3: Representación espacial del modelo RGB

Modelo CIE-Lab

CIE-Lab es un espacio de color creado para dar una representación perceptual del color. Este modelo de color presenta una gran inmunidad a los cambios de iluminación puesto que, una de sus componentes expresa precisamente esta intensidad, dejando los datos cromáticos libres de

cualquier perturbación que ocasione la iluminación [3].

La variable L representa la medida lumínica, mientras las componentes a y b definen los colores magenta –verde y amarillo-cyan respectivamente [2].




Figura 4: Representación espacial del modelo de color CIE-Lab

Características de los histogramas

Para el manejo y análisis de un gran número de datos, es conveniente utilizar representaciones cuantitativas de las características de estos. En este caso, se utilizan los histogramas, que son una representación gráfica de la distribución de frecuencia de los datos que componen a una muestra.

En algunos casos es necesario disminuir el número de datos a analizar, y para esto son utilizadas las medidas estadísticas. Estos datos se obtienen directamente del histograma, pueden ser: varianza, desviación estándar, media, mediana, moda, etc.

Estos valores nos pueden ayudar para la discriminación o clasificación de diferentes muestras [4].

Clasificación

En un problema de clasificación, tenemos como entrenamiento un conjunto de n muestras, cada una de ellas caracterizada por Y_k clases y X_k predicciones, la meta es encontrar un modelo que nos de los valores de Y que logran caracterizar o designar un determinado valor de X que esté de acuerdo a las características de la muestra analizada.

En teoría, la solución más fácil es dividir el espacio de X en k subconjuntos divididos tales que, para que pueda predecir que valores de Y pertenecen a cada uno de los sub espacios de X [5].

Arboles de clasificación

El método de árboles de clasificación permite crear un patrón recursivo que permite a cada dato elegir un valor de X de una manera más simple de interpretar.

Esta estructura de clasificación es aplicable a un número m de variables de clasificación, lo cual lo convierte en una herramienta muy eficaz [5].

MATERIALES Y MÉTODOS

Para la realización de este trabajo, se utilizaron diferentes muestras de cerámicos blancos, en total 120 imágenes, de las cuales 10 eran los especímenes de referencia o sin fallas, y 10 imágenes por cada magnitud del error presente, que van de 1 a 11 pixeles por falla.

Cada una de las imágenes mencionadas siguió el proceso que se describirá a continuación para poder ser clasificadas.

Lo primero fue calcular sus histogramas de color en los modelos RGB y CIE-Lab, se decidió trabajar en ambos espacios para contar con mayor cantidad de información cromática de cada imagen.

Se calcularon las medidas estadísticas media, mediana, moda y desviación estándar de cada componente de los modelos de color.




Figura 5: Histograma RGB de un cerámico de muestra (rojo: R; verde: G, azul: B)




Figura 6: Histograma CIE-Lab de un cerámico de muestra (amarillo: L; magenta: a; cian: b)

A partir de la hipótesis de que al presentarse una falla cromática en una muestra la posición del histograma, y por tanto las medidas estadísticas, cambian, se analiza una muestra con falla y se comparan los valores de sus características con los valores de una imagen sin fallas.

Al comprobar la hipótesis descrita, y saber que las medidas estadísticas son suficientes para poder realizar una clasificación, se utiliza el toolbox de MatLab llamado Classification Learner, para encontrar que componentes de los modelos de color RGB y CIELab nos permiten diferenciar con mayor probabilidad de éxito una muestra con fallas de una sin ellas.

Es importante mencionar que se analizará cada tamaño de falla por separado, para evitar confusiones.

Tabla 1: Comparación de medidas estadísticas RGB de una imagen con falla de 9 pixeles

| Cerámico | Media | | | Mediana | | | Moda | | | Desviación estándar | | |
|------------|--------|--------|--------|---------|-----|-----|------|-----|-----|---------------------|-------|------|
| | R | G | B | R | G | B | R | G | B | R | G | B |
| Sin fallas | 208.01 | 210.11 | 200.76 | 205 | 210 | 201 | 204 | 210 | 202 | 11.66 | 8.89 | 6.27 |
| Con fallas | 208.26 | 210.53 | 201.20 | 205 | 210 | 202 | 203 | 210 | 204 | 14.45 | 12.23 | 9.74 |

RESULTADOS Y DISCUSIÓN

Después de probar diversas combinaciones de las componentes de los dos modelos de color empleados en este trabajo, se encontró que, los árboles con mejor desempeño según el tamaño de la falla analizada fueron los expuestos en la tabla 2.

Tabla 2: Mejor porcentaje de acierto por tipo de falla

| Tamaño de falla | Componentes empleadas | Porcentaje de acierto |
|-----------------|-----------------------|-----------------------|
| 11 | B | 100 |
| 10 | B | 100 |
| 9 | B | 100 |
| 8 | B | 100 |
| 7 | L | 100 |
| 6 | B | 100 |
| 5 | B | 95 |
| 4 | L | 85 |
| 3 | B | 50 |
| 2 | R | 75 |
| 1 | B | 35 |

Matriz de confusión

Esta matriz nos muestra el porcentaje de cada uno de los 4 posibles casos en los que podría caer el algoritmo, que son:

Tabla 3: Tabla de posibles casos

| Entrada | Predicción |
|-----------|------------|
| Sin falla | Sin falla |
| Sin falla | Con falla |
| Con falla | Sin falla |
| Con falla | Con falla |

Tomando como ejemplo el árbol que nos entrega la peor predicción, el árbol de las fallas de tamaños de 1 pixel, la matriz de confusión es:

Tabla 4: Matriz de Confusión

| Clase verdadera | Predicción | |
|-----------------|------------|-----|
| | -1 | 1 |
| -1 | 20% | 30% |
| 1 | 35% | 15% |

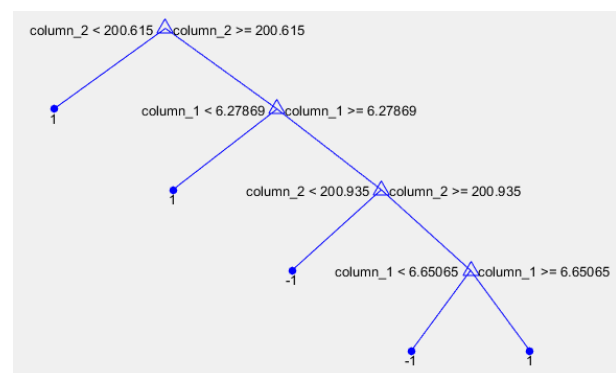


Figura 7: Árbol de clasificación de las muestras de 1 píxel de error

Algoritmo AdaBoost

Es un algoritmo de autoaprendizaje que permite la creación de clasificadores muy robustos en base a clasificadores débiles. A grandes rasgos, lo que hace este algoritmo es calcular T hipótesis diferentes en base a una muestra de datos n , a cada uno de los ejemplos de entrenamiento se le asigna un peso de acuerdo al error total de la hipótesis analizada. De igual forma es calculado un factor de error de cada clasificador (α_i). Al final, cada ejemplo de entrenamiento tiene t clasificaciones, una por hipótesis, esta es multiplicada por el factor de error y las t clasificaciones son sumadas, al final, el signo de estas sumas es el que determinará la hipótesis final. Es importante mencionar que para que este algoritmo sea más fácil de computar, las predicciones deben de ser de signo contrario, o sea, verdadero:1; falso: -1.

$$H(x) = \text{sign} \left(\sum_{t=1}^T \alpha_t h_t(x) \right) \quad (1)$$

Ecuación que rige la hipótesis final del algoritmo AdaBoost [6].

Es aplicado este algoritmo para calcular el clasificador de los cerámicos con error de 1 pixel, se ingresa un vector con las características de la componente B de 20 imágenes, las primeras 10 son imágenes sin errores (1) y las siguientes 10, tienen el error antes mencionado (-1). El algoritmo es aplicado por 5 iteraciones, y se obtiene como resultado:




Figura 8: Predicción de salida de muestras de un pixel de error utilizando el algoritmo AdaBoost

Con la ayuda de este algoritmo, obtenemos como resultado final, 11 clasificadores con un porcentaje de error del 0%.

CONCLUSIONES

El poder representar las características de un número tan grande de datos en simples valores y que con ellos se puedan clasificar por cambios tan pequeños, como lo es un solo pixel, nos da a conocer el gran alcance de la técnica empleada en este trabajo. De igual forma, el otro gran pilar de este trabajo, es el implementar un algoritmo no tan complejo que permita disminuir un el porcentaje de error a cero.

REFERENCIAS

- [1] Villalón Hernández, M. T., (2014). *Detección de fallas en cerámicos utilizando atributos de color-textura*, Tesis de licenciatura, Universidad de Guanajuato, México.
- [2] Ortiz Zamora, F. G., (2002). *Procesamiento morfológico de imágenes en color. Aplicación a la reconstrucción geodésica*, Tesis doctoral, Escuela Politécnica Superior, Alicante, España.
- [3] Ibarra M., M.A.; Devy, M. y Boizard, J. (2010) *Real-time classification based on color and texture attributes on an FPGA-based architecture*, Toulouse, Francia.
- [4] Unser, M., (1986), *Sum and Difference Histograms for Texture Classification*, Lausanne, Suiza.
- [5] Wei-Yin, L., (2011). *Classification and regression trees*, Madison, WI, USA.
- [6] Manzano Marcos, E., (2013). *Análisis y optimización de un algoritmo de segmentación de lumen en IVUS: estudio cuantitativo e implementación*, Universidad de Barcelona, Barcelona, España,