

ALGORITMO PARA LA DETECCIÓN DE FALLA EN PISOS CERÁMICOS

Guapo Mendieta, Diego (1), Ibarra Manzano, Mario Alberto (2)

1 [Ingeniería en Mecatrónica, Universidad de Guanajuato] | [diego.gm45@gmail.com]

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

Resumen

La calidad en los procesos de producción industrial es fundamental para evitar un producto final defectuoso. Para lograr una mejora en la calidad, es necesario identificar las fallas que puedan presentarse y encontrar una solución que reduzca o anule dichos defectos. En la industria de cerámicos, la inspección de calidad del producto final en algunas plantas se hace de manera visual, lo cual da lugar a una identificación de fallas no muy efectiva. En solución a esto, se propone una técnica utilizando visión por computadora que clasifique el cerámico, con el cual se determine el estado de la pieza. En este trabajo se implementó un algoritmo para la detección de fallas cromáticas en pisos cerámicos, específicamente manchas negras de dimensión variables, utilizando modelos estadísticos y árboles de decisión.

Abstract

Quality in industrial production processes is essential to avoid a deficient final product. To get an improvement in quality, is necessary to identify the flaws that may arise and find a solution to reduce or nullify these defects. In ceramic industry, the quality inspection of the final product in some plants is done by human observation, which results to a not very effective flaw identification. In solution to this, a technique is proposed using computer vision that classifies the ceramic and is determined the state of the piece. In this paper, an algorithm was implemented for the detection of chromatic flaws in ceramic floors, specifically black spots of variable dimension, using statistical models and decision trees.

Palabras Clave

Árboles de decisión; CIE-Lab; Clasificadores; Espacio de color; Visión por computadora.

INTRODUCCIÓN

Los cerámicos son materiales muy importantes en la construcción, se utilizan para revestimiento de suelos, paredes y productos de porcelana sanitaria. La gran cantidad de pisos cerámicos demandados ha hecho que la industria de estos se vea influenciada en el desarrollo de tecnologías de automatización para su fabricación. Algunas veces, existen defectos en la elaboración de los azulejos y es necesario identificarlos de una manera rápida, automática y eficiente para evitar contratiempos en las líneas de producción.

Cerámicos con fallas

Dentro de la producción de azulejos existen diversos factores que puedan deteriorar la calidad del cerámico, los cuales pueden presentarse al comienzo, a la mitad y al final del proceso de elaboración de este. Algunos ejemplos de fallos son azulejos rotos, bordes rotos, protuberancias, hoyos, manchas, grietas superficiales, defectos en la alineación de impresión y errores en la composición de textura. Debido a las diversas fallas que se pueden presentar, los pisos cerámicos son sometidos a inspecciones de calidad para la identificación y clasificación de los defectos, este control de calidad es realizado como una inspección visual bajo criterio del personal, la cual está sujeta al error humano.




FIGURA 1.1: Imagen captada de un cerámico blanco con defecto de color negro.




FIGURA 1.2: Imagen ampliada al 500% del mismo cerámico que la FIGURA 1.1.

Como se puede apreciar en la FIGURA 1.1, la falla cromática (mancha negra) se señala en el recuadro color rojo y esta es casi imperceptible a la vista humana, para poder ver la falla se necesita ampliar la imagen como se muestra en la FIGURA 1.2. Debido a esto, es necesario un sistema automático capaz de detectar fallas como las anteriores.

Color

Cuando se pretende definir o especificar el color es necesario realizar una distinción entre lo que se conoce como color percibido. Esta distinción es necesaria ya que en cada uno de los casos el color poseerá un significado distinto. En el caso subjetivo se considera el color como un aspecto de la percepción visual, mientras que en el caso objetivo éste es una característica de las radiaciones visibles. En ambos casos el color permite al observador distinguir las diferencias entre dos objetos de las mismas dimensiones, forma y/o estructura, siendo estas diferencias de la misma naturaleza que las producidas por una diferencia de composición espectral de la radiación que interviene en la observación [2].

Espacios de color

Los espacios de color proporcionan un método para especificar, ordenar y manipular colores. Estas representaciones se corresponden con n-dimensional ordenaciones de las sensaciones de color (vectores de n componentes). Los colores se representan mediante puntos en estos espacios. 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 tricromática de colores primarios rojo, verde y azul [2].

Modelo RGB

El modelo de color RGB (Red, Green, Blue) es el más utilizado ya que gran parte del hardware utilizado cotidianamente como pantallas y cámaras manejan el formato RGB. Gráficamente el espacio RGB se basa en un sistema de coordenadas cartesianas representado mediante un cubo, como el mostrado en la FIGURA 2 cada punto dentro del cubo representa un color particular. Los vértices del cubo son los colores primarios (rojo, verde y azul) y secundarios (cian, magenta y amarillo), el negro está en el origen y el blanco está en el vértice más alejado del origen [1].




FIGURA 2. Representación espacial del modelo RGB.

Modelo CIELAB

El modelo CIE $L^*a^*b^*$ se basa en el modelo de los colores opuestos. La variable L, es una medida de la luminancia, mientras que las componentes a y b definen las señales magenta-verde y amarillo-cian, respectivamente. En FIGURA 3 se puede observar la representación espacial de este modelo.

La transformación del modelo RGB a los espacios CIE $L^*a^*b^*$ no es inmediata. Los valores L^* , a^* y b^* se calculan, mediante transformaciones no lineales, haciendo uso del espacio XYZ. [1]




FIGURA 3. Representación espacial del modelo CIEL $^*a^*b^*$.

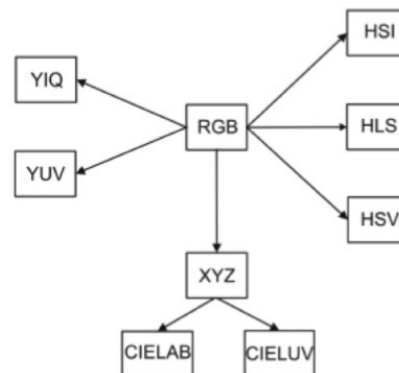


FIGURA 4. Modelos de espacio de color.

Clasificación

La clasificación, que es la tarea de asignar objetos a una de varias categorías predefinidas. Los datos de entrada para una tarea de clasificación son una colección de registros. Cada registro, se caracteriza por un par (x, y) , donde "x" es el conjunto de atributos y "y" es la clase o categoría. La función objetivo que mapea los elementos "x" a "y" también se conoce informalmente como un modelo de clasificación. [5]

Una técnica de clasificación es un enfoque sistemático para construir modelos de clasificación a partir de un conjunto de datos de entrada. Algunas de estas técnicas son árboles de decisión, clasificadores basados en reglas, redes neuronales y máquinas de vectores de soporte. Cada técnica emplea un algoritmo de aprendizaje para identificar el modelo que mejor se adapte a la relación entre el conjunto de atributos y la clase de los datos de entrada. El modelo generado por un algoritmo de aprendizaje debería ajustarse bien a los datos de entrada y predecir correctamente la clase de los registros que nunca se habían visto. [5]

Arboles de decisión

Un árbol de decisión es un clasificador expresado como una partición recursiva del espacio de instancia. Los árboles de decisión son una de las técnicas utilizadas en estos procesos, consiste sencillamente en un modelo de predicción en el cual en base a atributos que se seleccionaron de acuerdo con su importancia, se le describen diversas situaciones que pueden o no ser de conveniencia, estos le fueron provistos al árbol cuando fue construido para que diferencie lo aceptable de lo erróneo y así de esta forma de una respuesta en base a una serie de condiciones. [4]

En este trabajo, se analizaron imágenes de cerámicos de color blanco que presentan fallos en color negro de diferentes tamaños, provistas por la fábrica de Daltile. Este análisis fue hecho usando el modelo CIEL*a*b* en y usando árboles de decisión para la clasificación de las fallas en los cerámicos.

MATERIALES Y MÉTODOS

Para este trabajo se utilizó una base de 120 imágenes de cerámicos blancos que presentaban fallas de color negro que van desde 1x1 hasta 11x11 píxeles. Cada una de las imágenes fue sometida a una transformación del espacio RGB a XYZ y posteriormente a CIE L*a*b*.

El proceso que se hizo para las imágenes de cerámico de cada tamaño fue: primeramente, obtener una máscara en la cual se tenían identificadas las fallas de cada una de las imágenes para así obtener datos estadísticos de cada componente de la imagen en los píxeles con fallas identificadas en la máscara y obtener datos sin fallas de manera aleatoria para obtener los atributos clasificatorios y las clases.

Para el análisis estadístico de los píxeles, se analizó un píxel central y los píxeles con vecindad 1, 2 y 3 en distancia euclidiana [3], de esta forma el análisis es más general para otro tipo de imágenes donde puedan variar las condiciones en las que se adquieren. Otra ventaja de este método es que funciona mejor para imágenes donde las fallas no sean necesariamente rectangulares, sino que pueden tener formar irregulares, ya que se analizan en forma circular.




FIGURA 5.1. Análisis de píxeles con vecindad de tamaño 1.




FIGURA 5.2. Análisis de píxeles con vecindad de tamaño 2.




FIGURA 5.3. Análisis de píxeles con vecindad de tamaño 3.

Una vez obtenidos los datos clasificatorios de todas las imágenes, se hizo uso de una herramienta de Matlab, llamada Classification Learner, para analizar con qué medidas de tendencia central y con qué tamaño de vecindad se pueden encontrar modelos que nos permitan clasificar de mejor forma las muestras con falla y sin falla. Se hicieron análisis por tamaño de falla y un análisis general de todas las imágenes de cerámicos.

RESULTADOS Y DISCUSIÓN

Después de probar con diversos tamaños de vecindad, se encontró que la clasificación se realizaba de mejor forma con vecindad de tamaño 1, esto debido a que toma los pixeles son menos dispersivos y centran más las medidas estadísticas. Se decidió no tomar en cuenta la moda para el análisis, ya que los valores para las componentes a y b de las imágenes iban desde 0 hasta 7, por lo que se tiene que tomar en cuenta una precisión decimal que no es de mucho interés debido a que son pocos pixeles por analizar en cada medición.

Matriz de confusión

Una matriz de confusión proporciona la información necesaria para determinar qué tan bien se desempeña un modelo de clasificación, esta información se puede resumir con un solo número que haría que sea más conveniente comparar el rendimiento de los diferentes modelos. Este número se conoce como porcentaje de acierto.

Tabla 1. Matriz de confusión para cada clasificador.

		Clase estimada	
		Clase 0	Clase 1
Clase verdadera	Clase 0	f_{00}	f_{01}
	Clase 1	f_{10}	f_{11}

Los porcentajes con mejor desempeño de los árboles de decisión por cada medición son presentados en la Tabla 2.

Tabla 2. Mejor porcentaje de acierto con tamaño de vecindad 1.

Tamaño de falla	PORCENTAJE DE ACIERTO		
	Media	Mediana	Desviación estándar
1	40	40	50
2	92.2	100	62.8
3	96.6	99.8	80.4
4	95.9	99.8	79.9
5	97.9	99.9	89
6	98.2	100	88.1
7	98.1	100	89.6
8	98.2	100	91.3
9	98.8	100	91.8
10	98.9	100	93.2

11	99.1	100	94.5
Todas	98.5	99.9	95.4

Las componentes que se analizaron en la Tabla 2 fueron a y b, la componente L, que es representa la luminosidad no se tomó en cuenta debido a que la captura de las imágenes de los cerámicos se puede hacer en diferentes condiciones de luz, por lo que se tendrían diferentes valores de L, para un mismo cerámico, en cambio las componentes a y b se ven menos afectadas.

La medida de tendencia central que mejor desempeño da es la mediana, seguida por la media y la varianza. Se puede ver que conforme se analiza una imagen con un tamaño de falla más grande, se obtienen mejores resultados.

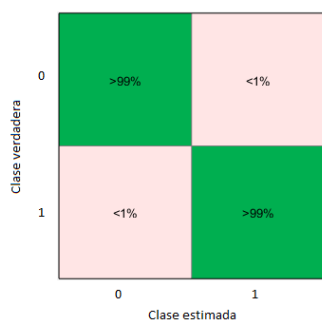


FIGURA 6.1. Matriz de confusión para fallas de tamaño 11.




FIGURA 6.2. Matriz de confusión para fallas de tamaño 1.

CONCLUSIONES

El uso de herramientas estadísticas como las medidas de tendencia central son de mucha utilidad para analizar el comportamiento de los componentes en una imagen. Es importante analizar una cantidad considerable de imágenes para tener una base con diversas condiciones en las que son capturadas, los cerámicos con fallas de tamaño grande aumentaron el porcentaje de acierto de clasificación, debido a la cantidad de información que se analizaba. Se pueden realizar pruebas y modificaciones al algoritmo para analizar fallas de diferente color y formas.

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] R. C. Gonzalez and R. E. Woods. Digital Image Processing (3rd Edition). Prentice-Hall, Inc., Upper Saddle River, NJ, USA, 2006.
- [4] Jihad Ali et al., (2002). Random Forests and Decision Trees. IJCSI International Journal of Computer Science Issues, Vol. 9, Issue 5, No 3.
- [5] Tao Li, Mitsunori Oghihara, George Tzanetakis., (2011). Music Data Mining. CRC Press. Boca Raton, FL.