

ALGORITMO PARA LA DETECCIÓN DE FALLA EN PISOS CERAMICOS

Valenzuela González, Israel Alexander (1), Ibarra Manzano, Mario Alberto (2)

1 Ingeniería Electrónica, Universidad de San Carlos de Guatemala | alex.valz19@gmail.com

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

Resumen

Los sistemas automáticos de verificación de calidad son muy importantes en los procesos de producción, en el caso de la producción de pisos cerámicos, la verificación de fallas durante la producción es un paso esencial para categorizar el piso en función de su calidad. Un atributo importante en la calidad de un piso cerámico es la uniformidad del color. El desarrollo de un algoritmo para detección de errores a través de imágenes, conlleva elegir desde el mejor espacio de color para analizar la imagen, hasta tener en cuenta el tipo de luz que ilumina al objeto de interés, de igual manera implica una minuciosa toma de datos de los cuales los mas sobresalientes serán tomados como atributos con el fin de obtener un clasificador tan eficiente como sea posible. Mediante el software MatLab se analizaron fotografías tomadas con fallas de distintos pixeles, tomando sus medidas de tendencia central como atributos, se propone el uso de imágenes en los espacios de color CIE-L*a*b* y RGB, con el fin de observar en cual de los dos se obtienen las componentes mas vulnerables al error y así encontrar el clasificador mas efectivo mediante arboles de decisión.

Abstract

Automatic quality verification systems are quite important in production processes, in the case of ceramic tiles production, failure verification during fabrication process is an essential fact to categorize the tiles in function of its quality. An important attribute on a tile's quality its a uniform color. The development of a failure detection algorithm through images, takes from choosing the best color space to analyze the picture to taking in count light's type illuminating the object of interest, implies at the same way a meticulous data collection from which the outstanding data will be taken as attributes with the final purpose of obtaining a classifier as efficient as possible. Images with different pixels failures were analyzed through MatLab software, taking their measures of central tendency as attributes, it intends the use of images on RGB and CIE-L*a*b* color spaces with the purpose of observing, which of them would provide the more failure vulnerable and find the effective classifier through decision trees.

Palabras Clave

Atributos de Color; Arboles de Decisión; Detección de Fallas; Supervisión Visual

INTRODUCCIÓN

Un espacio de color es una representación cuantitativa de los colores, donde cada color puede ser representado por un punto, esto tiene diversas utilidades, no solo de reconocimiento de fallas, sino de objetos también [1].

Espacio de color RGB

El modelo RGB, llamado así porque se pueden obtener todos los colores posibles con la unión de rojo, verde y azul [2]. Este espacio puede ser representado gráficamente como un cubo, figura 1, donde los vértices son los colores primarios y secundarios., el negro se encuentra en el origen (existiendo cuando todas las componentes son cero) mientras el blanco esta en el vértice más alejado en el origen (donde las 3 componentes alcanzan su valor máximo) [3]. Es utilizado hoy en día por varios aparatos y programas como su espacio de color predefinido.

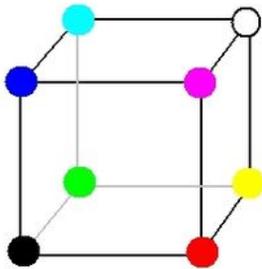


FIGURA 1: Descripción grafica del espacio de color RGB.

Espacio de color CIE-L*a*b*

El espacio de color CIE-L*a*b* fue adoptado por la CIE en el año 1976 con el fin de utilizarlo como un estándar para los espacios de color. Este modelo fue ampliamente aceptado debido a la uniformidad que se buscó al crearlo, el propósito era obtener un espacio de color lineal, con un pequeño cambio en sus valores numéricos, obtener de igual manera a si mismo un pequeño cambio

visiblemente notorio. En este caso sobresale la componente L* puesto que esta determina la luminosidad en la imagen, mientras a* cuanto mas positivo, se acerca mas al rojo y viceversa para el verde. En el caso de b* varia de amarillo a azul respectivamente como se observa en la figura 2. Se llevo a cabo de esta forma debido a la teoría del color oponente que establece que dos colores no pueden ser rojo y verde al mismo tiempo, mismo caso para el amarillo y azul.

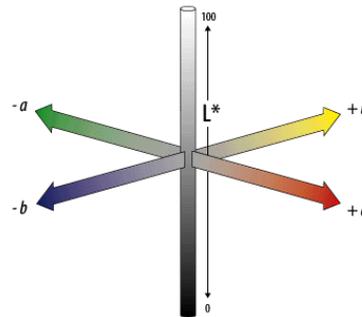


FIGURA 2: Descripción grafica del espacio de color CIE L*a*b*.

Minería de datos

La minería de datos es el proceso de detectar patrones o información de interés en grandes cantidades de información que son muy complejas y extensas para ser analizadas por métodos más tradicionales. Los arboles de decisión son una de las técnicas utilizadas en estos procesos [4], que ésta muy relacionado con la inteligencia artificial, consiste sencillamente en un modelo de predicción en el cual en base a atributos que se seleccionaron de acuerdo a 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(lo que se le llama entrenar al árbol) y así de esta forma de una respuesta en base a una serie de condiciones [5]. El entrenamiento puede ser realizado de diversas maneras cuando no se tienen suficientes datos la validación cruzada es una herramienta que nos auxilia en la construcción de un árbol de decisión ya que se encarga de seleccionar una cantidad de datos para entrenar al árbol y otra para probar que

este funcione. Esto ayuda a tener un árbol más completo especialmente cuando fue construido con una pequeña muestra.

Es necesario hoy en día contar con un sistema que pueda detectar fallas en de una manera rápida y eficiente en un sistema de producción, en la industria de los pisos cerámicos, se producen diversos tipos de errores, entre estos los de color, que consisten en cierta parte decolorada del cerámico debido a que la boquilla que rocía la pintura se encuentra parcial o totalmente bloqueada. Han sido desarrollados muchos algoritmos para resolver fallas incluso de textura [3].

Es necesario hoy en día contar con un sistema que pueda detectar fallas de una manera rápida y eficiente en un sistema de producción. En este proyecto se trabajó con imágenes de cerámicos con falla por pintura que fueron analizadas en el espacio de color RGB y CIE-L*a*b*, donde se seleccionaron sus atributos más sobresalientes para luego concluir en el modelo más conveniente para este caso y así obtener los arboles de decisión que son fundamentales para la creación del algoritmo.

MATERIALES Y MÉTODOS

MatLab

MatLab es un software orientado a resolver problemas científicos y de ingeniería. En este caso es utilizado por la amplia gamma de opciones que ofrece en el análisis de imágenes, de igual forma posee varias herramientas útiles en el tratamiento cuantitativo de datos, en el área de la estadística, lo que nos permite tener herramientas disponibles para crear, entrenar y utilizar arboles de decisión de formas simples y complejas.

Imágenes de cerámicos

Las imágenes nos fueron provistas por la fábrica de Daltille en Salamanca, en un espacio de color originalmente en RGB. El sistema de toma de fotografías ya se encontraba implementado al momento de iniciar el proyecto.

Arboles de decisión

Los árboles de decisión fueron utilizados como la estructura principal del algoritmo en base a las medidas de tendencia central más determinantes, como atributos, determinaron los patrones que diferenciaban un piso con falla de uno correcto.

Las muestras, de los distintos errores posibles, así como los aciertos, eran relativamente pocas, por lo que la validación cruzada nos fue de utilidad para dar solidez a los resultados.

RESULTADOS Y DISCUSIÓN

A continuación, se encuentra una tabla con las medidas de tendencia central para la componente B del espacio de color RGB, en la cual se muestra una muestra por cada error y una para cuando no hay falla en lo absoluto.

Tabla 1: Medidas de tendencia central para la componente B en el espacio de color RGB.

Tipo de falla (pixeles)	B			
	Media	Mediana	Moda	Varianza
Sin Fallas	201	201	202	33
1	201	201	202	33
2	201	202	204	38
3	202	202	204	43
4	201	201	202	43
5	203	203	204	57
6	201	201	203	59
7	202	203	204	69
8	202	203	204	86
9	202	202	204	97
10	201	201	204	108
11	202	203	204	123

Se observa en la tabla de arriba que la varianza es para este caso el único atributo que varía, hay que recalcar que en las fallas más pequeñas, este último ya no es tan efectivo por sí mismo, por lo que es necesario auxiliarlo con la media, mediana y moda, dependiendo del caso. Se utilizó únicamente esta componente en RGB debido a que no había variaciones considerables en R y G y no son relevantes en la clase.

Tabla 2: Medidas de tendencia central para la componente L en el espacio de color CIE L*A*B*.

Tipo de falla en pixeles	L			
	Media	Mediana	Moda	Varianza
Sin Fallas	215	214	212	77
1	215	214	213	78
2	215	214	212	79
3	214	213	211	78
4	214	213	211	76
5	215	214	213	92
6	214	213	211	92
7	215	214	212	119
8	215	214	213	125
9	215	214	212	139
10	214	213	211	153
11	215	214	214	173

En la tabla 2 se muestra la componente L del espacio CIE-L*a*b*, donde la varianza es nuevamente el atributo a resaltar, ya que las demás medidas se mantienen siempre similares. En este caso se observa que a diferencia de B en RGB, hallamos que nos será necesario auxiliarnos

con otra medida al llegar a la falla 6 aproximadamente.

Se muestran los datos obtenidos en la componente en L* debido a que tanto en a* y b* son datos que no tienen cambio alguno con o sin falla. Se considera que los datos de la componente en L* serían más valiosos si las fotografías se tomaran con una fuente de luz controlada, y no una natural, ya que en algunos casos se obtuvieron porcentajes de las muestras que se salían de los parámetros y alteraban la capacidad de los árboles de decisión, visiblemente se observa en las imágenes los cambios de luminosidad por lo que se asume fueron tomadas a distintas horas del día.

Podemos afirmar luego de ver las características de las imágenes en los distintos espacios de color, que nos será conveniente el uso de RGB en este caso, debido a la notoria distancia que poseen las varianzas entre sí. Lo que facilita el reconocimiento de error.

En la figura 3 se observa el histograma de la componente en L* con una distribución gaussiana transpuesta, se observa que hay cierta dispersión considerable en los datos.

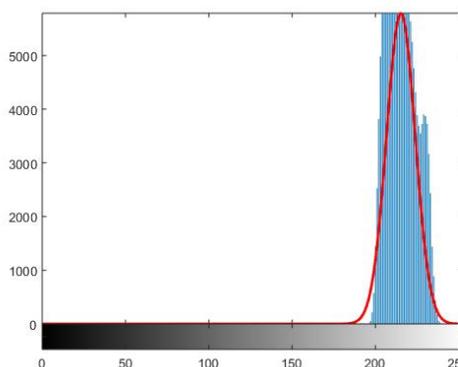


FIGURA 3: Histograma de componente L, con gaussiana transpuesta.

En la figura 4 obtenemos el histograma para la componente en B, con lo cual observamos la uniformidad de la misma. Podemos afirmar luego de ver las características de las imágenes en los distintos espacios de color, que nos será conveniente el uso de RGB en este caso, debido a la notoria distancia que poseen las varianzas entre sí. Así como la uniformidad de la misma, que ya

con un error le afectara notoriamente y facilitara el reconocimiento de error.

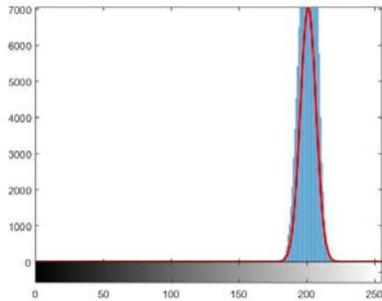


FIGURA 4: Histograma de componente B, con gaussiana transpuesta.

A consecuencia de lo anterior se obtuvieron los árboles de decisión, se muestra la matriz de confusión obtenida para distinguir entre errores de 10 y 9 pixeles, se observa en la figura 5. Se halla una clara distinción entre ambos errores, por parte del árbol, eficiencia del 100%.

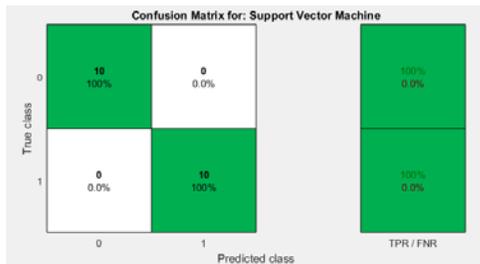


FIGURA 5: Histograma de componente B, con gaussiana transpuesta.

CONCLUSIONES

Las medidas de tendencia central en las imágenes RGB tienden a ser más dispersas que en las de CIE-L*a*b*. Exceptuando a las componentes B y L* respectivamente.

CIE-L*a*b* mostraría mejores resultados en sus atributos si las imágenes fueran tomadas bajo una luz artificial controlada.

La componente en L varía más en sus características que a* y b* debido a que el tipo de falla implica un oscurecimiento de la imagen.

La componente B varía más que R y G debido al tipo de color (negro) que implica esta falla y afecta a la misma de forma directa.

La validación cruzada le dio solidez al trabajo ya que se contaban con pocas muestras para analizar.

Los árboles de decisión fueron fundamentales para hallar patrones en los errores más pequeños y dar una respuesta tolerable al error.

AGRADECIMIENTOS

Mi eterno agradecimiento a la Universidad de Guanajuato por permitirme ser parte del 4to. Verano de investigación.

Al Dr. Mario Ibarra por apoyarme desde el proceso de aplicación al verano, así como por su asesoría durante el transcurso del mismo, siempre transmitiendo sus conocimientos de la mejor forma posible.

Al laboratorio de DSP por proveerme de un espacio útil y agradable para trabajar.

A Dios, cuya voluntad me trajo hasta acá y le agradezco por eso..

REFERENCIAS

- [1] Hernández, J., Quintanilla, A., López, J., Rangel, F., Ibarra, M., Almanza, D., Villalón, Hernández, M. (2012). Detecting objects using color and depth segmentation with Kinect sensor. *Procedia Technology*, volume (3), 196-204,200(3).
- [2] Ortiz, Zamora, (2002). Procesamiento Morfológico de Imágenes en Color. Aplicación a la Reconstrucción Geodésica. Phd thesis, Escuela Politécnica Superior, Alicante, España.
- [3] Villalón, Hernández, M.(2014). Detección de fallas en cerámicos utilizando atributos de color-textura. Thesis, Universidad de Guanajuato, Salamanca, México.
- [4] De Knijf, Jeroen. FAT-CAT: Frequent Attributes Tree Based Classification. Universiteit Utrecht, Utrecht, Holanda.
- [5] Loh, W.Y, (2011). *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*. John Wiley & Sons, Inc. Classification and Regression trees. En A. A.