

ANÁLISIS Y CLASIFICACIÓN DE LADRILLOS DE HORMIGÓN CELULAR A TRAVÉS DE IMÁGENES

Rodrigo Ortiz de Zárate, Lucas Ríos, Gisela Roncaglia

Instituto de investigación en señales, sistemas e inteligencia computacional, sinc(i) UNL-CONICET

Director/a: Enrique M. Albornoz

Codirector/a: César E. Martínez

Área: Ingeniería¹

Palabras claves: ladrillo de hormigón, texturas, procesamiento de imágenes.

INTRODUCCIÓN

Los ladrillos de hormigón celular curado en autoclave (HCCA) son altamente usados hoy en día en las construcciones [Macedo, 2020]. Estos poseen muchas propiedades que los hacen muy eficientes, entre estas se encuentran: buena aislación térmica; alta resistencia a la penetración de agua líquida; mayor aislamiento acústico; gran resistencia al fuego; menor peso y mayor duración [Visión Técnica, 2015]. Entre el 60% y el 90% de la estructura de estos ladrillos se compone por poros. Estos son los responsables de las propiedades mencionadas anteriormente. Por lo tanto, es fundamental que el proceso de fabricación sea correcto para lograr una adecuada presencia y distribución de poros, con el fin de obtener óptimos resultados.

OBJETIVOS

El objetivo de este trabajo es generar una herramienta que, a partir del procesamiento de imágenes permita determinar si un ladrillo cumple con los requerimientos mínimos para ser considerado un ladrillo apto para el ambiente de la construcción.

Objetivos específicos

- Definir y desarrollar un protocolo de captura de imágenes en una escena particular.
- Estudiar, implementar y comparar diferentes procedimientos que permitan caracterizar a los ladrillos a partir de una fotografía.
- Definir e implementar métodos para clasificar los ladrillos en aptos y no aptos.

METODOLOGÍA

Base de datos de imágenes

Como primer paso fue necesario generar una base de datos de imágenes de ladrillos, para esto se diseñó y configuró una escena particular. En la figura 1 y 2 puede verse la configuración final elegida, donde se utiliza una mesa contra la pared, cubierta con una tela de color negro. Sobre la mesa se coloca cada ladrillo de tamaño 100x100[mm] con diferentes distribuciones de poros. Se decidió que la escena debía ser interior para poder ajustar la iluminación, y evitar que la luz solar influya en la escena. Esto permite reproducir la escena de forma precisa para realizar nuevas capturas. Respecto a la iluminación, se utilizaron dos luces LED de 12 watts ubicadas a los lados del ladrillo a 42 cm de distancia. Esta configuración fue el resultado de varias pruebas a partir de las cuales se determinó que es importante

¹ Proyecto acreditado en el que se enmarca la investigación: CAI+D 2020 50620190100145LI "Desarrollo de métodos de aprendizaje automático para redes neuronales computacionales en grafos con aplicaciones al análisis de imágenes". Director: César E. Martínez

generar sombras en los poros, para facilitar su detección y así disminuir el post-procesamiento requerido al momento de utilizar las imágenes.




Figura 1: Esquema de la escena.




Figura 2: Esquema de la escena.

Finalmente, se obtuvieron 64 imágenes de 3872*2592px, 44 correspondientes a ladrillos aptos y 20 a ladrillos no aptos. A partir de este conjunto de imágenes y con el fin de focalizar el trabajo en el análisis de poros, se decidió generar otro conjunto de imágenes extrayendo una región de 1080*1080px centrada de cada ladrillo. Con este conjunto se realizarán los análisis que se detallan a continuación.

Procedimientos de segmentación

En este primer enfoque se pretende encontrar y segmentar cada uno de los poros de la superficie, con el fin de obtener una estimación de la densidad de poros en la superficie. Con base en dicha proporción, se determina la clasificación final del ladrillo.

1. Segmentación

Este procedimiento consiste en los siguientes pasos:

- Umbralizado adaptativo Gaussiano: se binariza una imagen mediante un umbral dinámico, obteniendo una imagen representativa de los poros.
- Apertura morfológica y eliminación de elementos del borde [Gonzales y Woods, 2008]: se separan aquellos poros que aparecen unidos, sin perder su tamaño original, y se eliminan los que tocan el borde de la imagen, para facilitar el conteo.
- Búsqueda de componentes conectados [Gonzales y Woods, 2008]: esto permite etiquetar cada poro como un objeto individual y brinda características útiles para la clasificación.

Finalmente, se dispone de cada poro y su área en píxeles. Luego, se calcula el área total de la zona libre de poros, obteniendo así un único valor por cada imagen.

2. Umbralización de entropía y segmentación

Para este segundo método se calcula una imagen de entropía con el fin de cuantificar el 'desorden' presente y se la procesa con los pasos descritos en el método 1. Se utiliza como kernel un disco de tamaño de 3px y la fórmula 1, donde $P(x_i)$ es la probabilidad de ocurrencia:

$$H(x) = -\sum_{i=1}^n P(x_i) \log P(x_i) \quad (1)$$

Procedimientos basados en texturas

La textura de una superficie hace referencia a la distribución de valores de intensidad a nivel espacial, y a partir de estas se puede obtener fácilmente propiedades como: fineza, rugosidad, etc. En base a una comparativa de estos valores a lo largo de todas las imágenes, obtendremos las propiedades que definen un ladrillo apto o no apto.

3. Matriz de co-ocurrencia (GLCM)

La matriz GLCM [Avinash, 2020] almacena valores que explican con cuánta frecuencia un píxel se relaciona espacialmente con otro. Se las considera medidas de segundo nivel, ya que involucran una relación estadística entre un píxel en cierta ubicación espacial y otro desplazado cierta distancia y dirección respecto de la ubicación del primer píxel.

Aquí, se calcula la matriz GLCM para cada una de las imágenes disponibles y a estas matrices se le calculan las siguientes propiedades: 'contraste', 'disimilitud', 'homogeneidad', 'ASM', 'energía' y 'correlación'. Todas estas componen un vector que es utilizado como entrada para el proceso de clasificación.

4. Filtrado de Gabor

El filtro de Gabor [Avinash, 2020] es un filtro lineal que nos permite identificar el contenido frecuencial de una imagen en una dirección y zona de estudio determinada. Este se define en base a un kernel cuya expresión se muestra en la fórmula 2:

$$Kernel = \exp\left(-\frac{x'^2 + y'^2}{2\sigma^2}\right) \exp\left(i\left(2\pi\frac{x'}{\lambda} + \psi\right)\right) \begin{cases} x' = x \cos \theta + y \sin \theta \\ y' = -x \sin \theta + y \cos \theta \end{cases} \quad (2)$$

donde σ es la desviación estándar, λ es la relación de aspecto espacial, λ es la longitud de onda, ψ es la fase y θ es la orientación de la normal de las paralelas de la función. Para las pruebas se establece que σ pertenece a [1:5] con paso 2, θ pertenece a [0: π] con paso $\pi/4$ y ψ pertenece a [0.05,0.5], logrando así generar 24 kernels por cada imagen. Estos son aplicados sobre la zona de interés para generar 24 imágenes filtradas, y a cada una de estas se le calculará su media. De esta manera, tendremos 24 propiedades para cada una de las imágenes, conformando el vector de características que se utilizará en el proceso de clasificación.

5. Local binary pattern (LBP)

El método de LBP es una medida de segundo nivel, mediante la cual se genera una matriz que almacena datos correspondientes a una relación entre los píxeles. En este caso se genera una matriz que almacena valores que relacionan un píxel con sus vecinos, evaluando si cada vecino es mayor o menor que el píxel central, según la fórmula 3:

$$\sum_{n=0}^7 s(i_n - i_c)2^n = \sum_{n=0}^7 s(z)2^n = LBP \text{ Code} \quad s(z) = \begin{cases} 1, & z \geq 0 \\ 0, & z < 0 \end{cases} \quad (3)$$

donde i_n representa al píxel vecino, i_c es el píxel central, n representa el número de vecinos. Este resultado se guarda en la matriz LBP para cada una de las imágenes disponibles y a esta se le calcula el histograma, al cual se lo conoce como "Vector de características" y es la entrada para el proceso de clasificación.

Clasificación

Con cada uno de los procedimientos se extrajo una o varias características que se utilizan luego para el procedimiento de clasificación mediante el algoritmo de k-vecinos más cercanos (KNN) [Onel, 2018]. Este está basado en una función de distancia euclídea y una elección de k-vecinos más cercanos. El procedimiento considera un caso de prueba, encuentra los K vecinos más cercanos en el espacio de características y en base a esto se toma una decisión sobre la clase a la que pertenece el caso de prueba. Se lo clasifica como un algoritmo supervisado, el cual es muy útil para conjuntos de datos pequeños y sin una cantidad grande

de características. A continuación, se presenta los resultados obtenidos para cada uno de los métodos propuestos.

RESULTADOS Y CONCLUSIONES

Dado que hay un desbalance de clases, se separó en ladrillos aptos y no aptos. Primero se dividió el conjunto de imágenes de forma aleatoria en 80% para entrenamiento y 20% para prueba, considerando el desbalance. El bloque de entrenamiento se volvió a dividir en 80% para entrenamiento propiamente dicho y 20% para validación (para evitar el sobre-entrenamiento). El entrenamiento se repitió 500 veces para distintos valores de K-vecinos y luego se computó un promedio de los resultados, utilizando la métrica F1-Score. En la Figura 2, se puede ver la evolución para distintos K de los que se selecciona el K-óptimo para la prueba final con datos de prueba nunca vistos. En la Tabla 1 se ven los resultados después de repetir el proceso 10 veces y promediando los valores obtenidos.




Tabla 1: resultados del clasificador

Método	K óptimo	F1-Score para conjunto de prueba
1	10	82.50%
2	6	80.75%
3	2	96.56 %
4	1	94.67 %
5	7	98.88 %

Figura 2: elección del k-óptimo

En este trabajo se propusieron métodos de segmentación basados en umbralización, que permiten una sencilla interpretabilidad en los resultados con un rendimiento aceptable (figura 2). Sin embargo, tienen una excesiva dependencia a las características de la imagen respecto de la forma de captura. Por otro lado, los métodos basados en texturas hacen más difícil la interpretabilidad, como asociar un vector a la cantidad de poros. Sin embargo, con estos se obtienen resultados más precisos y mantienen una independencia muy deseable respecto de la condiciones de luz, por lo que es de esperar que funcione bien con imágenes capturadas en otras escenas.

BIBLIOGRAFÍA BÁSICA

Gonzales R., Woods R., 2008. Morphological image processing. Digital image processing third edition, pp. 642-676. Editorial Pearson. New Jersey

Avinash K., 2020. Measuring Texture and Color in Images. Purdue University

<https://engineering.purdue.edu/kak/Tutorials/TextureAndColor.pdf>

Onel H., 2018. Accedido 20 de junio de 2021, <https://towardsdatascience.com/machine-learning-basics-with-the-k-nearest-neighbors-algorithm-6a6e71d01761>

Visión Técnica - Portal de construcción, 2015. Accedido 20 de junio de 2021 <http://www.visiontecnica.com.ar/index.php/nuevos-materiales/8-hormigon-celular-curado-en-autoclave>

Macedo L., 2020. Construcción en seco vs tradicional de ladrillo. Accedido 20 de junio de 2021 <https://webcapp.com/blog/index.php/2020/04/07/diferencias-sistema-construccion-en-seco-vs-tradicional/>