

Análisis y clasificación de ladrillos de hormigón celular a través de imágenes

Rodrigo Ortiz de Zarate, Lucas Rios, Gisela Roncaglia,
César Martínez, Enrique M. Albornoz

¹ Instituto de investigación en señales, sistemas e inteligencia computacional, sinc(i) UNL-CONICET, Ciudad Universitaria, Ruta Nacional N° 168, km 472.4, (3000) Santa Fe.
Facultad de Ingeniería y Ciencias Hidricas – Universidad Nacional del Litoral
rodrigoortz@gmail.com, luucas125@outlook.com.ar, giselaroncaglia@gmail.com,
{cmartinez, emalbornoz}@sinc.unl.edu.ar

Resumen. Actualmente, el área de la construcción sostenible está enfocada en minimizar la utilización de recursos y promover el uso de técnicas constructivas innovadoras a partir de materiales que reduzcan la demanda energética, de recursos y con bajo impacto en el ambiente. El objetivo de este trabajo es generar una herramienta que permita determinar de manera sencilla y automática, si un ladrillo cumple con los requerimientos mínimos para ser un ladrillo apto para el ambiente de la construcción. La base de datos de imágenes ha sido relevada en una escena desarrollada para este trabajo. Se evaluaron diversas técnicas de procesamiento digital de imágenes para la extracción de características y se utilizó el método de KNN para clasificar las imágenes de los ladrillos. Finalmente, se compara y discute la efectividad de cada uno de estos métodos a partir de los resultados obtenidos que son prometedores.

Palabras claves: poros, hormigón, ladrillo, segmentación de imágenes, textura

1 Introducción

En la industria de la construcción, la producción de hormigón, desde la extracción hasta su transporte, genera casi un 10% del CO₂ emitido mundialmente. Esta industria, con sus procesos y productos involucrados, es una de las más nocivas para el medio ambiente [1]. En la actualidad, en Argentina, el sistema constructivo de ladrillo y cemento es el más difundido. Es por esto que surge como prioridad promover sistemas eficientes que fomenten un menor consumo de recursos, mayor rapidez en la ejecución de la obra, menor cantidad de residuos producidos, menor consumo de agua, entre otras características [2]. Hoy por hoy, los ladrillos de hormigón celular curado en autoclave (HCCA) son altamente usados en las construcciones, esto se debe a su sencillo y eficiente sistema constructivo [3], además de ser mucho más amigables con el medio ambiente. Estos se forman por una mezcla de aglomerantes (principalmente cemento y una proporción de cal), áridos finos (arena cuarcita finamente molida), agua y un agente expansor que genera millones de burbujas de aire en cada ladrillo a partir de una reacción química [4]. Esta estructura celular le otorga al HCCA muchas propiedades

que lo hacen muy eficiente, entre éstas se encuentran [3,4]: buena aislación térmica debido a la gran cantidad de “cámaras de aire” cerradas e incomunicadas que se encuentran en la masa; alta resistencia a la penetración de agua líquida, ya que la textura cerrada tiene prácticamente nula succión capilar; mayor aislamiento acústico debido a la reducción de las ondas sonoras en el paso sucesivo a través de las “cámaras de aire”; gran resistencia al fuego; menor peso y mayor duración; entre otras. Entre el 60% y el 90% de la estructura de estos ladrillos se compone por poros y 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.

Los poros presentes en el ladrillo pueden clasificarse como microporos y macroporos. Los microporos tienen tamaños que oscilan entre 100 nm y 0,1mm [5]. Para el análisis de estos se utilizan técnicas particulares propias de la mecánica como “porosimetría de intrusión de mercurio”, donde se inserta una sustancia como mercurio líquido y se obtiene a partir de esto la distribución de la porosidad en función del tamaño aparente de acceso a los poros [6]. Por otro lado, los macroporos tienen tamaños entre 0,5mm y 2mm [7], y pueden ser analizados con técnicas de procesamiento de imágenes.

En el presente trabajo, se abordan diferentes metodologías para la clasificación y distinción entre ladrillos aptos y no aptos, comenzando desde técnicas más básicas de segmentación a través de umbralización simple, hasta el análisis de propiedades estadísticas usando métodos de caracterización de texturas. Además, fue necesario generar una base de datos de imágenes para la que se configuró una escena particular y se detalla a continuación para poder replicar o extender la experimentación.

2 Metodología

En esta sección se detallarán cada uno de los pasos realizados para el desarrollo del modelo final, desde la creación de una base de datos de imágenes específica.

2.1 Base de datos de imágenes

La escena, que puede verse en las Figuras 1 y 2, se configuró posicionando una mesa apoyada contra la pared. Ambas fueron cubiertas con una tela de color negro, con el fin de lograr un contraste con el color blanco del ladrillo. Sobre la mesa se coloca cada ladrillo de tamaño 100x100mm 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. De esta manera, las fotos pueden ser registradas en distintos momentos del día y no se genera falta de homogeneidad en la iluminación, lo que dificultaría el tratamiento de las imágenes. Esto permite, además, reproducir la escena de forma precisa para realizar nuevas capturas y aumentar la base de datos con imágenes similares. En cuanto a la iluminación artificial de la escena, se utilizaron dos luces LED de 12 Watts 6500 K ubicadas a los lados del ladrillo, a 42 cm de distancia. Esta configuración fue el resultado de pruebas preliminares con las cuales se determinó

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




Fig. 1. Esquema de la escena con la que se capturaron las imágenes, indicando distancia, dirección y ángulo de inclinación de cada elemento.




Fig. 2. Escena real (izquierda), región de interés (derecha).

Para la adquisición de imágenes se utilizó una cámara Nikon D3000 con un lente 18-55mm f/5,6 configurando un tiempo de exposición de 1/160 y cuyos resultados son archivos JPEG con una resolución de 3872x2592px. Finalmente, se obtuvieron 64 imágenes, 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 1080x1080px centrada de cada ladrillo. Con este conjunto se realizarán los análisis que se detallan a continuación.

2.2 Procedimientos de segmentación

En un primer abordaje nos concentramos en encontrar y segmentar cada uno de los poros de la superficie, con el fin de obtener el área que estos ocupan. De esta manera podremos conseguir una estimación cercana de la proporción que está siendo cubierta por poros en la región de interés. En base a dicha proporción, determinaremos la clasificación final del ladrillo.

2.2.1 Método de umbralización adaptativa y segmentación

En este primer método, nos enfocamos en la búsqueda de cada poro en la imagen. El procedimiento consiste en los siguientes pasos (esquematizados en la Fig. 3):

- Umbralización adaptativa Gaussiana [8]: este método se basa en la binarización de una imagen mediante el cálculo de un valor de umbral en un área pequeña, obteniendo diferentes umbrales para diferentes áreas. Así, se obtiene una imagen representativa de los poros del ladrillo.
- Apertura morfológica: esta operación consiste en la aplicación de una erosión, seguida de una dilatación morfológica utilizando un mismo elemento estructurante [9]. Con esto se logran separar aquellos poros que aparecen unidos sin perder el tamaño original de los poros.
- Eliminación de elementos del borde: se realiza una limpieza de aquellos objetos que están sobre el borde de la imagen aplicando operaciones morfológicas con el fin de facilitar el conteo de poros.
- Búsqueda de componentes conectados: este método se utiliza para localizar, en una imagen binaria, cada elemento desconectado del resto (en este caso, los poros) [9]. Esto permite etiquetar cada uno como un objeto individual y brinda características útiles para la clasificación.

Finalizados estos pasos, se dispone de cada poro y su área representada en píxeles, la cual usaremos para determinar la densidad de poros en la superficie. Se calcula el área total de la zona que no se considera poro, es decir, la diferencia entre el área total de la imagen y el área sumada de todos los poros. De esta manera, se tiene un único valor de área por cada imagen, el cual se utilizará en el proceso de clasificación.



Fig. 3. Secuencia de procesamiento del método basado en umbralización adaptativa.

2.2.2 Método de umbralización de entropía y segmentación

Este segundo método no utiliza la imagen tal como fue capturada, sino que se calcula una imagen de entropía con el fin de cuantificar el ‘desorden’ presente en la imagen del ladrillo y es ésta imagen la que se procesa con los pasos descritos en 2.2.1 (ver Fig. 4). Para esto, se genera una imagen de entropía utilizando como kernel un disco de 3px y la siguiente fórmula [10], donde $P(x_i)$ es la probabilidad de ocurrencia:

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




Fig. 4. Secuencia de procesamiento del método basado en entropía.

2.3 Procedimientos de segmentación basados en texturas

Debido a la forma irregular que presentan los poros en el ladrillo, se presentan casos donde segmentarlos se vuelve muy difícil, más aún si no se dispone de un sistema de iluminación que recree la escena utilizada en este trabajo. Esta es una primera apreciación con base en las pruebas iniciales, en trabajos futuros se evaluará la robustez de los métodos para diferentes configuraciones de escenas. Es esperable que los métodos basados en texturas tomen relevancia en contextos más difíciles. 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, suavidad, etc. En base a una comparativa de estos valores a lo largo de todas las imágenes, obtendremos las propiedades que definen un ladrillo apto y uno no apto.

2.3.1 Método basado en la matriz de co-ocurrencia (GLCM)

La matriz GLCM almacena valores que explican con cuánta frecuencia se relaciona espacialmente un píxel de un nivel de gris con otro píxel con otro nivel de gris específico. A estas matrices se las considera medidas de segundo nivel, ya que involucran una relación estadística entre un píxel en cierta ubicación espacial y otro píxel desplazado cierta distancia y dirección respecto del primer píxel [11]. Aquí (ver Fig. 5), se calcula la matriz GLCM para cada una de las imágenes disponibles y a estas matrices se le calculan diferentes propiedades: 'contraste', 'disimilitud', 'homogeneidad', 'ASM', 'energía' y 'correlación'. Cada una de estas propiedades serán utilizadas como entrada para el proceso de clasificación.



Fig. 5. Secuencia de procesamiento del método basado en GLCM.

2.3.2 Método basado en filtrado de Gabor

El filtro de Gabor es un filtro lineal que nos permite identificar el contenido frecuencial de una imagen en una dirección específica y en una zona de estudio determinada. Este se define en base a un kernel cuya expresión es la siguiente [11]:

$$Kernel = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \exp\left(i\left(2\pi\frac{x'}{\lambda} + \psi\right)\right) \quad (2)$$

donde σ es la desviación estándar, γ 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 líneas paralelas de la función y

$$\begin{cases} x' = x \cos \theta + y \sin \theta \\ y' = -x \sin \theta + y \cos \theta \end{cases} \quad (3)$$

Teniendo en cuenta esta expresión, es posible ver que la variación de cualquiera de los parámetros provoca la generación de un kernel distinto y, por lo tanto, existe una cantidad enorme de posibilidades. Para las pruebas realizadas aquí, se establece que σ pertenece a [1:5] con paso 2, θ pertenece a [0: π] con paso $\pi/4$ y γ pertenece a [0,05:0,5], logrando así, generar una colección de 24 kernels por cada imagen. Estos kernels son aplicados sobre la zona de interés para generar 24 imágenes filtradas de una misma imagen y a cada una de estas imágenes filtradas se le calculará su media. De esta manera, tendremos 24 propiedades disponibles sobre cada una de las imágenes, y estas conforman el vector de características que se utilizarán en el proceso de clasificación (un esquema de este proceso se ve en la Figura 6).



Fig. 6. Secuencia de procesamiento del método basado en filtro de Gabor.

2.3.3 Método de patrones binarios locales (LBP)

El método de LBP, al igual que GLCM, es una medida de segundo nivel, mediante la cual se genera una matriz que almacena datos correspondientes a una relación entre los píxeles [12]. 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 siguiente expresión [13]:

$$\sum_{n=0}^7 s(i_n - i_c)2^n = \sum_{n=0}^7 s(z)2^n = \text{Codigo LBP} \quad (4)$$

donde i_n representa al píxel vecino, i_c es el píxel central, n representa el número de vecinos y $s(z)$ está definido según la siguiente expresión [13]:

$$s(z) = \begin{cases} 1, & z \geq 0 \\ 0, & z < 0 \end{cases} \quad (5)$$

Este resultado se guarda en la matriz. Aquí, se obtiene la matriz LBP para cada una de las imágenes disponibles y a dicha matriz se le calcula el histograma, al cual se lo conoce como “vector de características” y es la entrada para el proceso de clasificación.

2.4 Clasificación

Tal como se mencionó anteriormente, con cada uno de los procedimientos se extrajo una o varias características que se utiliza luego para el procedimiento de clasificación mediante el algoritmo de k-vecinos más cercanos (KNN) [14]. Este es uno de los algoritmos más simples de implementar y proporciona una buena precisión de clasificación. El algoritmo KNN (Fig. 7) está basado en una función de distancia euclídea y una función de voto de k-vecinos más cercanos. El procedimiento considera un cierto caso de prueba, encuentra los K vecinos más cercanos (vecinos correspondientes a los casos de entrenamiento) en el espacio de características y en base a esto se toma una decisión sobre la clase a la que pertenece este caso de prueba. En el ámbito del aprendizaje automático, este método se clasifica como un algoritmo supervisado, el cual es muy útil para conjuntos de datos pequeños y sin una cantidad grande de características, por esto fue considerado como el algoritmo a utilizar para este trabajo.



Fig. 7. Procedimiento de clasificación utilizando KNN.

3 Resultados y discusiones

De cada método propuesto, se extrajeron las características que son utilizadas en el clasificador. Para los métodos 2.2.1 y 2.2.2 se usó el valor del área obtenida por la segmentación como característica distintiva, para el método 2.3.1 se utilizaron las 6 características extraídas de la matriz GLCM. Luego para el método 2.3.2 se usó la media de las imágenes filtradas, obteniendo 24 características distintivas y, finalmente para el método 2.3.3 se utilizó el vector de 28 valores presentes en el histograma.

El desbalance presente en las clases se tuvo en cuenta a la hora de separar los ejemplos 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

propriadamente dicho y 20% para validación (evitando el sobre-entrenamiento) [15,16]. La exploración se repitió 500 veces y se consideraron distintos valores de K-vecinos (de 1 a 10), y luego se computó un promedio de los resultados, utilizando las métricas F1-Score y UAR (del inglés, *Unweighted Average Recall*). El objetivo fue encontrar el mejor K para cada método y luego realizar la evaluación sobre el conjunto de test.

En las figuras 8 y 9 se puede ver cómo se comporta el clasificador para cada uno de los métodos, variando la cantidad de vecinos utilizados en el algoritmo. De esta forma es posible encontrar el K óptimo en cada caso. Los primeros dos métodos (referidos a segmentación) dan resultados muy similares entre ellos, por debajo de los otros y mejoran su rendimiento según aumenta el K. La diferencia puede estar asociada a la cantidad de características extraídas para cada método. En un trabajo futuro se evaluará la combinación de las distintas características.

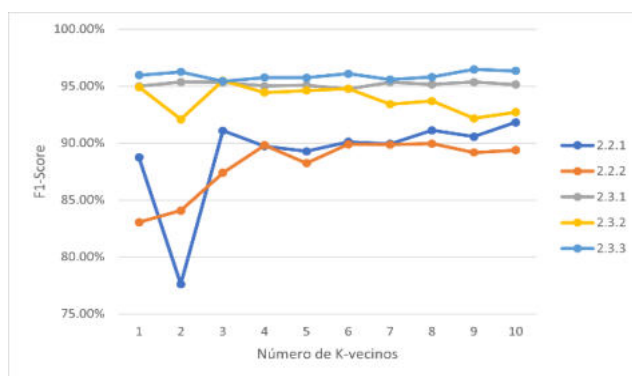


Fig. 8. Resultados promedio para la búsqueda del mejor K (F1-Score).




Fig. 9. Resultados promedio para la búsqueda del mejor K (UAR).

Una vez obtenidos los K óptimos de cada método, se procede a realizar la evaluación final sobre los datos de prueba que no fueron utilizados. Este proceso completo se repitió 10 veces, donde se promediaron los porcentajes resultantes. Debido a que las 10 repeticiones vuelven a generar aleatoriamente los grupos de entrenamiento y prueba, el K óptimo puede variar levemente en cada repetición, por lo que se utilizó la moda estadística para determinar el resultado final, mostrado en las Tablas 1 y 2.

Tabla 1. Resultados finales utilizando K óptimo basado en F1-Score.

Método	K óptimo	F1-Score	UAR
2.2.1	10	90,51 %	85,00 %
2.2.2	5	88,14 %	84,03 %
2.3.1	2	98,41 %	96,94 %
2.3.2	1	96,42 %	91,25 %
2.3.3	2	96,60 %	95,28 %

Tabla 2. Resultados finales utilizando K óptimo basado en UAR.

Método	K óptimo	F1-Score	UAR
2.2.1	10	86,60 %	75,00 %
2.2.2	8	87,51 %	77,50 %
2.3.1	2	99,00 %	97,50 %
2.3.2	1	94,83 %	88,19 %
2.3.3	7	95,93 %	94,72 %

Con base en estos resultados, es posible decir que los métodos basados en texturas siempre dan resultados superiores a los de segmentación. Cuando se utiliza F1-Score para la búsqueda del K óptimo, se obtiene al menos un 6% absoluto más sobre UAR. Mientras que, cuando se busca el K óptimo sobre UAR, se obtiene una diferencia de más del 10%. Si bien LBP funciona muy bien, el método basado en GLCM obtiene los mejores resultados. Su rendimiento es muy prometedor ya que presenta menos de un 2,5% de error para las métricas analizadas.

4 Conclusiones y trabajos futuros

En este trabajo se propusieron métodos para clasificar un ladrillo de hormigón celular en aptos para su uso o no. Para esto, se propusieron métodos de segmentación basados en umbralización, los cuales permiten interpretabilidad en los resultados, ya que se pueden inferir directamente la cantidad de poros, sus tamaños, entre otras propiedades. Los resultados obtenidos con estos métodos fueron bastante buenos, como se puede observar en los experimentos presentados. Sin embargo, sigue siendo un procedimiento problemático, debido a su 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, ya que no es posible determinar ciertas cuestiones simples, como la cantidad de poros. No obstante, con éstos métodos se obtienen resultados más certeros y una independencia muy deseable respecto de las condiciones de luz, por lo que sería posible un margen de variación de la escena mucho mayor.

Como trabajo futuro, se prevé aumentar el número de imágenes en la base de datos para confirmar el buen comportamiento del modelo. Además, se realizarán análisis para comprobar si los métodos tienen robustez a los cambios en la escena. A mediano plazo se propone la captura de imágenes con cámaras de celular, la realización del proceso en tiempo real y validar la usabilidad en ambientes reales no controlados.

Agradecimientos

Los autores desean agradecer al instituto sinc(i) UNL-CONICET, a UNL (con CAI+D 50620190100145LI) y al ingeniero Federico Ortiz de Zarate por su apoyo y contribución como asesor temático.

Referencias

1. Macedo, L.: Construcción en seco vs tradicional de ladrillo, <https://webcapp.com/blog/index.php/2020/04/07/diferencias-sistema-construccion-en-seco-vs-tradicional/>.
2. Gobierno nacional argentino: Vivienda y construcción sostenible, <https://www.argentina.gob.ar/ambiente/desarrollo-sostenible/vivienda>.
3. Dejtiar, F.: ¿Qué es el hormigón celular curado en autoclave y cuáles son sus ventajas en la arquitectura?, <https://www.plataformaarquitectura.cl/cl/918535/que-es-el-hormigon-celular-curado-en-autoclave-y-cuales-son-sus-ventajas-en-la-arquitectura>.
4. Visión Técnica: Hormigón Celular Curado en Autoclave, <http://www.visiontecnica.com.ar/index.php/nuevos-materiales/8-hormigon-celular-curado-en-autoclave>.
5. Qu, X., Zhao, X.: Previous and present investigations on the components, microstructure and main properties of autoclaved aerated concrete – A review. *Construction and Building Materials*. 135, pp. 505--516 (2017).
6. Rodríguez, J.: Porosimetría por inyección de mercurio 1st ed. Universidad de Oviedo, Oviedo (2002), http://ocw.uniovi.es/pluginfile.php/4888/mod_resource/content/1/T3b-PorosimetriaMercurio.pdf.
7. Wan, H., Hub, Y., Liu, G., Qu, Y.: Study on the structure and properties of autoclaved aerated concrete produced with the stone-sawing mud. *Construction and Building Materials*. 184, pp. 20--26 (2018).
8. Bradski, G.: "The OpenCV Library". Dr. Dobb's Journal of Software Tools, (2000).
9. Gonzales, R., Woods, R.: Digital Image Processing 3rd ed. In: McDonald, M. (ed.). Pearson Prentice Hall, pp. 642--676 (2008).
10. Van Der Walt, S., Schönberger, J. L., Nunez-Iglesias, J., Boulogne, F., Warner, J. D., Yager, N., Gouillart, E., Yu, T. and the scikit-image contributors: scikit-image: Image processing in Python. *PeerJ* 2:e453 (2014)
11. Kak, A.: Measuring Texture and Color in Images 2nd ed. Purdue University, Indiana (2020), <https://engineering.purdue.edu/kak/Tutorials/TextureAndColor.pdf>.
12. Rosebrock, A.: Local Binary Patterns with Python & OpenCV, <https://www.pyimagesearch.com/2015/12/07/local-binary-patterns-with-python-opencv/>.
13. Sairamya, N.J., Susmitha, L., George, S.T., Subathra, M.S.P.: Intelligent Data Analysis for Biomedical Applications. In: Hemanth, D. J., Gupta, D., Balas, V. E. (eds.). Academic Press, pp.253--273 (2019).
14. Harrison, O.: Machine Learning Basics with the K-Nearest Neighbors Algorithm, <https://towardsdatascience.com/machine-learning-basics-with-the-k-nearest-neighbors-algorithm-6a6e71d01761>.
15. Scikit-learn: Machine Learning in Python, Pedregosa et al., *JMLR* 12, pp. 2825--2830 (2011).
16. Bishop, Christopher M. "Pattern recognition." *Machine learning* 128.9 (2006).