



Índice de Redondez de Krumbein mediante Mapas Autoorganizativos de Kohonen

Krumbein Roundness Index using Kohonen Self-Organizing Maps

Juan Sebastián Useche Castelblanco ¹, Oscar Javier Reyes Ortiz ²,
Marcela Mejía ³

Para citar este artículo: J. S. Useche Castelblanco, O. J. Reyes Ortiz, M. Mejía, "Índice de Redondez de Krumbein mediante Mapas Autoorganizativos de Kohonen", Revista Vínculos, vol 19, no. 2, pp 191-206, 2022. <https://doi.org/10.14483/2322939X.15753>

Recibido: 29-05-2022 / Aprobado: 07-08-2022

Resumen: Dentro de las áreas de conocimiento que abarca la ingeniería, la aplicación de inteligencia artificial y procesamiento digital de imágenes ha permitido automatizar procesos que tradicionalmente se realizaban de forma manual. En el área de pavimentos, diferentes herramientas digitales se han implementado para la parametrización del tipo de fragmentos de roca que se utiliza para la construcción de vías y carreteras,

ayudando en el mejoramiento del proceso de diseño de estas estructuras, las cuales, bajo el contexto actual son fundamentales para el transporte de mercancías esenciales y para la recuperación económica de una región. De esta forma en este trabajo se implementa un algoritmo mediante el análisis de imágenes y redes neuronales para la determinación del índice de redondez de Krumbein del agregado en pavimentos flexibles. Lo anterior con el

1 Ingeniero en Mecatrónica, magíster en Ingeniería, estudiante doctoral en Ciencias Aplicadas e Investigador, Universidad Militar Nueva Granada, Colombia. E-mail: u7700125@unimilitar.edu.co

2 Ingeniero Civil y magíster en Ingeniería, Universidad de los Andes, Colombia. Doctor en Ingeniería Civil, Universidad Politécnica de Cataluña, España. Profesor titular / Universidad Militar Nueva Granada, Colombia. E-mail: oscar.reyes@unimilitar.edu.co

3 Doctora en Ingeniería, Universidad de los Andes, Colombia. Doctora en Telemática, Universidad Politécnica de Cataluña, España. Profesor titular Universidad Militar Nueva Granada, Colombia. E-mail: angela.mejia@unimilitar.edu.co

objetivo de generar una herramienta que permita automatizar un proceso que convencionalmente implica el desplazamiento y tiempo de trabajo de un ingeniero para el desarrollo del diseño de la mezcla.

Palabras clave: Análisis de imágenes, Pavimentos flexibles, SOM, Krumbein.

Abstract: Within the areas of knowledge that engineering encompasses, the application of artificial intelligence and digital image processing has made it possible to automate processes that were traditionally carried out manually. In the area of pavements, different digital tools have been implemented for the parameterization of the type of rock fragments used for the construction of roads and highways. These tools improve the design process of pavement structures, which, under the current context, pavements are essential for the transport of essential goods and the economic recovery of a region. In this work, an algorithm is implemented through the analysis of images and neural networks to determine the Krumbein roundness index of the aggregate in flexible pavements. To generate a tool that allows automating a process that conventionally involves the displacement and work time of an engineer for the development of the mixture design.

Keywords: Image analysis, Flexible Pavement, SOM, Krumbein.


1. Introducción

Las carreteras y vías son parte central en el crecimiento económico y social de un país, sobre todo bajo condiciones especiales como la del COVID – 19. Estas estructuras permiten el transporte de mercancías que suplen las necesidades básicas de las regiones, teniendo un impacto no solo a nivel social, si no también colaborando en la recuperación económica de las empresas [1][2]. Mejorar los procesos de diseño de un pavimento inciden en el desarrollo de estructuras más duraderas y agilizan los procesos de construcción [3].

Una estructura de pavimento está compuesta por agregados pétreos (fragmentos de roca) y por un ligante (cemento para pavimentos rígidos y asfalto para pavimentos flexibles). Las propiedades físicas de estos materiales se relacionan directamente con el comportamiento y desempeño que podría llegar a tener una de estas estructuras [4]. Para la evaluación de este comportamiento se realizan una serie de ensayos de laboratorio, en diversos estudios se aplica una descripción del material pétreo que compone la mezcla con el fin de parametrizar su posible respuesta y desempeño [5].

Diferentes trabajos han demostrado la relación que existe entre la morfología del agregado y el comportamiento mecánico de un pavimento [6]. En donde el tipo de geometría puede incrementar la resistencia de la estructura ante deformaciones o las irregularidades en la superficie influyen en la resistencia de la estructura al agrietamiento [7][8]. De forma convencional la parametrización de la forma de los fragmentos de roca se realiza mediante inspección manual y tomando longitudes del agregado en el sitio de acopio [9].

Figura 1. Redondez de Krumbein [10].



También existen diferentes cartillas gráficas que permiten realizar una clasificación del agregado de una forma más ágil, ya que la medición manual de longitudes estos requieren mayor tiempo. Krumbein presenta un gráfico para agregados que establece el índice de redondez de la partícula mediante la comparación visual entre el fragmento de roca y las imágenes (Figura 1) [10]. Dentro del gráfico se

observa que se presentan 9 grupos con 9 agregados cada uno. Cada grupo representa un índice de redondez desde 0.1 (agregado angular) hasta 0.9 (agregado redondo).

Con la aparición de los sistemas digitales estos procesos de medición y comparación que se realizaban de forma manual han migrado mediante la implementación de algoritmos computacionales, inteligencia artificial y procesamiento de imágenes a sistemas que permiten obtener resultados más fácilmente [11]. Dentro del contexto actual la implementación de estas tecnologías ayuda a evitar el desplazamiento y estancia del ingeniero en sitio por un mayor periodo de tiempo. Existen diferentes trabajos realizados en la descripción del tipo de agregado mediante herramientas digitales como el desarrollado por Lili Pei et al. en [12] donde aplicando bosques aleatorios realiza la clasificación de los agregados teniendo en cuenta 6 clases, dentro de las cuales se encuentran los fragmentos angulares, cúbicos, elongados, rugosos, rugosos alargados e irregulares. El sistema tiene una exactitud de 0.74 en promedio. Otro trabajo realizado es el de Khalid et al. en [13] donde implementa un sistema de visión de máquina para determinar el índice de elongación de los agregados. La aplicación tiene un error máximo del 10% en comparación con las mediciones manuales. Para finalizar los autores

Joonyoung Kim et al. Implementan una herramienta de trabajo con imágenes que realiza la medición de la angularidad, redondez, índice de forma y esfericidad mediante la aplicación de expresiones matemáticas y mediciones digitales[14].

De acuerdo con lo revisado, actualmente los algoritmos se han desarrollado profundamente en la medición y parametrización de diferentes características del agregado, pero dentro de estas no se evidencia la aplicación de algoritmos computacionales para la determinación del índice de Krumbein, por tanto, en este trabajo se implementa un sistema basado en redes neuronales que acopla un mapa autoorganizativo de Kohonen y una red multicapa para la determinación del índice de redondez de Krumbein. Esto con el objetivo de aportar en el desarrollo de sistemas de inspección del agregado, que

permitan una parametrización en la descripción del fragmento de roca que se utiliza para la construcción de carreteras, permitiendo agilizar los procesos de diseño y disminuyendo el tiempo del ingeniero en sitio.

2. Métodos y materiales

En la Figura 2 se presenta el esquema del trabajo realizado, inicia con el proceso de adquisición de la imagen del pavimento flexible y termina con la validación del modelo de predicción del índice de redondez de Krumbein.

2.1 Adquisición

La adquisición de la imagen es realizada con una cámara convencional de 18 mega pixeles ubicada a 20 centímetros de la

Figura 2. Modelo de trabajo.






Figura 3. Captura de imágenes.



muestra e iluminada con luz led blanca. En la Figura 3 se observa el protocolo de adquisición de la imagen y la captura de dos mezclas asfálticas de diferentes características.

La imagen capturada con la cámara es una imagen a color RGB. Para poder realizar la identificación del agregado se debe realizar la segmentación e individualización de las partículas. Para la separación de los fragmentos de roca es necesario tener en cuenta que este tipo de materiales presentan dos particularidades. El primero, es la tonalidad oscura que presentan algunos agregados que pueden confundirse con el asfalto (fondo). Por otro lado, el pavimento flexible en su fabricación pasa por un proceso de compactación por el cual los bordes entre agregados no están claramente definidos [15]. En la Figura 4 se observan los diferentes casos.

Figura 4. Puntos Críticos.



2.2 Segmentación

La segmentación del agregado se realiza de acuerdo con lo presentando en [15] en donde por medio de diferentes técnicas de procesamiento de imágenes se abordan los puntos críticos y se obtiene una segmentación con un porcentaje de error inferior al 4% en comparación con la curva de diseño en laboratorio que se realiza de la mezcla. El modelo de segmentación del agregado contempla una etapa de binarización de la imagen centrada en la aplicación del método Otsu. Lo anterior con el objetivo de realizar la binarización del agregado teniendo en cuenta las diferentes intensidades que se presentan a lo largo de la imagen, como consecuencia de la diversidad de los diferentes tipos de agregados y de perturbaciones externas que se presentan al momento de la captura de la fotografía [16][17]. De esta forma en la


Figura 5 se presenta un ejemplo de la binarización del agregado.

Figura 5. Mezcla asfáltica binarizada.



Para la separación del material se aplica la operación morfológica de Opening verificando que el tamaño de la estructura de la convolución sobre la imagen no realice una modificación por encima del 95% con respecto al material original [18]. Esto con el objetivo de evitar una modificación excesiva del agregado que

Figura 6. Llenado de partículas y morfologías.



interfiera dentro del modelo de predicción del índice. Un ejemplo de lo anterior se observa en la Figura 6, en donde previamente se aplicó una función para el llenado de huecos presentes en la binarización provenientes de los poros de los fragmentos de roca.

Para el cálculo y la obtención de los parámetros de caracterización del

agregado detectado dentro de la foto, se realiza un proceso de individualización de las partículas. Para esto se localizan los objetos y se extraen los agregados creando imágenes nuevas por cada fragmento de roca como se ilustra en la Figura 7. La separación se realiza tanto en blanco y negro como a color.

Figura 7. Fragmentos de roca individualizados.




Tabla 1. Funciones de descripción [7][21]


Orden	Parámetro	Ecuación	Parámetros	Año	Autor
Primer	Circularidad	$C = \frac{P^2}{4\pi A}$ (1)	A área, P perímetro del agregado.	1998	Janoo
Primer	Rectangularidad	$Re = \frac{A}{A_r}$ (2)	A área de partícula, A_r área de rectángulo enmarcado	1999	Kwan
Segundo	Convexidad	$Co = 1 - \frac{Ac}{A}$ (3)	Ac área convexa de la partícula, A área de partícula.	2000	Mora
Segundo	Índice de forma	$RA = \frac{M_a}{m_a}$ (4)	M_a eje mayor, m_a eje menor de la partícula.	2001	Masad

Dentro de la cartilla gráfica de Krumbein se presentan 9 grupos diferentes dentro de los cuales cada uno tiene 9 patrones de agregado. El implementar un algoritmo como una red neuronal convolucional no es eficiente, ya que la morfología del agregado tiene una alta variabilidad y la cantidad de imágenes necesarias para poder aplicar un clasificador de 9 etiquetas es elevada [19]. De esta forma la solución propuesta es realizar una caracterización numérica de cada uno de los agregados propuestos por Krumbein, con la cual un algoritmo como los mapas autoorganizativos de Kohonen pueden realizar una parametrización de las regiones dentro de las cuales los fragmentos de roca muestren características similares y se pueda realizar una mejor clasificación.

2.3 Caracterización numérica (CN)


Las diferentes expresiones matemáticas para el cálculo de los parámetros utilizados en la caracterización numérica de los agregados de Krumbein y los agregados de validación del modelo se muestran en la Tabla 1. Estos parámetros están orientados a realizar una parametrización de cada una de las partículas en función de la forma general del agregado y la forma del elemento en sus bordes, estos valores se denominan parámetros de primer y segundo orden (Figura 8) [20][14].

Figura 8. Descripción de agregados.



Aplicando las ecuaciones anteriores sobre los agregados individualizados se calculan los parámetros numéricos de caracterización. Para la obtención de los valores, primero se realiza la medición de diámetros, ejes y polígonos, y posteriormente se aplican las ecuaciones. En la Figura 9 se ilustra la medición de diferentes partículas.

El algoritmo se aplica a cada uno de los agregados y genera una tabla con los valores para cada partícula. En la Figura 10 se presenta el resultado para agregados de diferentes características. De esta forma estos cuatro valores son lo que presenta cada partícula en la entrada del modelo, luego de realizar su estandarización utilizando su media y desviación estándar.

Figura 9. Medición de parámetros.

Con la caracterización numérica de cada uno de los agregados en la siguiente sección se genera el clasificador con el cual se automatizará el proceso de determinación del índice de redondez de Krumbein, que de forma convencional se realiza comparando de forma visual el agregado versus las imágenes de cada uno de los 9 grupos de la cartilla gráfica. Dentro de la solución se plantea un clasificador mediante mapas autoorganizativos, que en la salida se acopla con una red neuronal multicapa. Lo anterior con el objetivo de poder crear regiones de cada índice mediante el algoritmo no supervisado y luego con el resultado hacer la clasificación supervisada del índice. El desarrollo del modelo se presenta a continuación.

2.4 Clasificador SOM – MPL

Para la generación automática del índice de redondez de Krumbein se implementa un mapa autoorganizativo de Kohonen

(SOM). Estos mapas son estructuras de redes neuronales que se conectan en forma de plana [22], permitiendo crear cortezas neuronales artificiales como la expuesta en la Figura 11.

Estas cortezas tienen la capacidad de generar zonas de activación de acuerdo con estímulos externos o datos con los que fueron entrenados. Para este caso, los valores de entrenamiento son el resultado de la aplicación de la caracterización numérica para cada uno de los 81 agregados diseñados por Krumbein. A fin de predecir el índice de redondez de cada uno de los agregados se acopla al SOM una red neuronal MLP que tiene como función interpretar el mapa de activación y dar una respuesta (Rango de 0.1 a 0.9). Se implementa el SOM con el objetivo de que se creen zonas de activación flexibles que permitan la posterior clasificación de agregados desconocidos. El esquema del sistema se presenta en la Figura 12.

Figura 10. Resultado de la caracterización numérica




Figura 11. Mapas autoorganizativos de Kohonen[22].





Figura 12. Modelo para índice de redondez.



De esta forma dentro de la corteza neuronal artificial generada se delimitan 9 regiones en donde se ubican los diferentes grupos propuestos por Krumbein. Se observa como los agregados de Krumbein quedan distribuidos en la Figura 13 con una corteza de 100 neuronas.

Una vez con el entrenamiento del mapa se genera el entrenamiento de la capa MLP, con una capa de entrada de 100 neuronas y una salida de 9 (una por cada índice de redondez). De esta forma el sistema tiene la capacidad de establecer el parámetro de redondez de acuerdo con el grafico de Krumbein para los diferentes agregados de entrada. Todos los hiperparámetros de los modelos son sintonizados mediante el método de Random Search con el fin de poder obtener la mejor configuración [23].

3. Resultados

En la Figura 14 se presenta la respuesta y el mapa de activación para 30 agregados segmentados de la imagen de un pavimento flexible.

Se debe resaltar que la respuesta del modelo es en función de un sistema entrenado con tan solo 9 imágenes por tipo de clase. Para la validación del sistema se determinaron las diferentes métricas de clasificación en los 81 datos de entrenamiento y los 80 agregados segmentados de una imagen de pavimento flexible y clasificados visualmente por un experto, los resultados obtenidos se presentan en la Tabla 2.

Figura 13. Mapa de activación.




Figura 14. Respuesta del modelo.




Tabla 2. Métricas del modelo.

Krumbein	Precisión	Recall	F1 - Score	N. Muestras	Datos de Entrenamiento
0,1	1,0	1,0	1,0	9	
0,2	1,0	1,0	1,0	9	
0,3	1,0	1,0	1,0	9	
0,4	1,0	1,0	1,0	9	
0,5	1,0	1,0	1,0	9	
0,6	1,0	1,0	1,0	9	
0,7	1,0	1,0	1,0	9	
0,8	0,9	1,0	0,95	9	
0,9	1,0	0,89	0,94	9	
Precisión			0,99	81	
Krumbein	Precisión	Recall	F1 - score	N. Muestras	Datos de Validación
0,1	1,0	0,91	0,95	11	
0,2	1,0	0,82	0,9	33	
0,3	1,0	1,0	1,0	5	
0,4	0,7	1,0	0,82	7	
0,5	0,85	0,85	0,8	2	
0,6	0,33	1,0	0,5	1	
0,7	1,0	1,0	1,0	5	
0,8	0,5	1,0	0,67	2	
0,9	1,0	1,0	1,0	3	
Precisión			0,89	80	

Dentro de los resultados de la tabla anterior con los datos de entrenamiento, se encuentra que el sistema tiene la capacidad de demarcar completamente las regiones de activación creadas con el SOM. Este resultado es necesario ya que, al tener únicamente 9 elementos para el entrenamiento de 9 clases, los mapas de activación para cada uno de los índices de Krumbein deben delimitarse completamente para que no exista un traslape entre las fronteras de decisión.

Los resultados de los datos de validación muestran una caracterización clara de la mezcla que es lo que se busca cuando se implementan este tipo de herramientas. Estos valores de prueba fueron tomados de una fotografía capturada de un espécimen de pavimento flexible, los resultados muestran que ese pavimento tiene una concentración de agregado altamente angular (índices entre 0.1 – 0.3). No se esperaba tener una distribución uniforme dentro de las clases ya que se están validando 80 agregados de una muestra única y el agregado con el cual fue fabricado proviene de una misma parte. De esta forma es evidente que este agregado comparta características morfológicas muy similares debido a su mismo origen.

Analizando los resultados de validación los índices en donde se tiene más de 5 partículas por clase muestran un F1-Score por encima de 0.8. De igual forma tomando

la media de precisión se obtiene un resultado de 0.89 al comparar la clasificación automática versus la realizada visualmente por el experto, mostrando un elevado porcentaje de efectividad del método. Mediante estos resultados se comprueba preliminarmente el funcionamiento de la herramienta, en donde es necesario realizar un mayor número de segmentaciones manuales en mezclas de pavimento flexible, fabricados con agregados de un punto de extracción que brinde una morfología más redonda para poder tener una clara distribución dentro de todas las clases.

4. Conclusiones

El modelo desarrollado presenta un buen desempeño dentro de la clasificación de agregados angulares con una exactitud de 0.88, es decir, con un índice de redondez de Krumbein entre 0.1 y 0.5. Como trabajo futuro se está determinando la capacidad del modelo presentado al incluir agregados con características morfológicas más redondas. Lo anterior con el objetivo de tener un número de partículas representativas dentro de todas las clases.

La implementación de mapas autoorganizativos de Kohonen enlazados con una estructura de redes neuronales multicapa, permitió desarrollar un sistema

supervisado con la capacidad de poder determinar el índice de redondez de Krumbein, el cual es un factor de descripción del tipo de agregado de un pavimento. Por medio de esta herramienta es posible disminuir el tiempo de diseño de las estructuras al hacer automático un procedimiento que tradicionalmente se realiza de forma manual al tomar agregado por agregado y compararlo con un patrón gráfico. Generar este tipo de herramientas con imágenes bajo el contexto actual permite reducir la manipulación de los materiales y el tiempo en los laboratorios de diseño.

Agradecimientos

Este producto es derivado del proyecto de alto impacto IMP-ING-2931 financiado por la vicerrectoría de investigaciones de la Universidad Militar Nueva Granada, a la cual los autores agradecen.

Referencias

- [1] C. Katrakazas, E. Michelaraki, M. Sekadakis, and G. Yannis, "A descriptive analysis of the effect of the COVID-19 pandemic on driving behavior and road safety," *Transp. Res. Interdiscip. Perspect.*, vol. 7, 2020, <https://doi.org/10.1016/j.trip.2020.100186>
- [2] P. Pereira and J. Pais, "Main flexible pavement and mix design methods in Europe and challenges for the development of an European method," *J. Traffic Transp. Eng. (English Ed.)*, vol. 4, no. 4, pp. 316–346, 2017, <https://doi.org/10.1016/j.jtte.2017.06.001>
- [3] A. P. Singh, A. Sharma, R. Mishra, M. Wagle, and A. K. Sarkar, "Pavement condition assessment using soft computing techniques," *Int. J. Pavement Res. Technol.*, 2018.
- [4] Z. Zhang, Q. Liu, Q. Wu, H. Xu, P. Liu, and M. Oeser, "Damage evolution of asphalt mixture under freeze-thaw cyclic loading from a mechanical perspective," *Int. J. Fatigue*, vol. 142, no. June 2020, pp. 1–9, 2021, [doi: 10.1016/j.ijfatigue.2020.105923](https://doi.org/10.1016/j.ijfatigue.2020.105923)
- [5] K. B. Bai Kamara, E. Ganjian, and M. Khorami, "The effect of quarry waste dust and reclaimed asphalt filler in hydraulically bound mixtures containing plasterboard gypsum and GGBS," *J. Clean. Prod.*, vol. 279, 2021. [doi: 10.1016/j.jclepro.2020.123584](https://doi.org/10.1016/j.jclepro.2020.123584)
- [6] D. M. Kusumawardani and Y. D. Wong, "The influence of aggregate shape properties on aggregate packing in porous asphalt mixture (PAM)," *Constr.*

- Build. Mater.*, vol. 255, 2020. [doi: 10.1016/j.conbuildmat.2020.119379](https://doi.org/10.1016/j.conbuildmat.2020.119379)
- [7] T. M. Al Rousan, "Characterization of aggregate shape properties using a computer automated system," Texas A&M University, 2004.
- [8] C. García-González, J. Yepes, and M. A. Franesqui, "Geomechanical characterization of volcanic aggregates for paving construction applications and correlation with the rock properties," *Transp. Geotech.*, vol. 24, January, 2020. [doi: 10.1016/j.trgeo.2020.100383](https://doi.org/10.1016/j.trgeo.2020.100383)
- [9] J. Hu and P. Stroeve, "Shape characterization of concrete aggregate," *Image Anal. Stereol.*, vol. 25, no. 1, pp. 43–53, 2006. [doi: 10.5566/ias.v25.p43-53](https://doi.org/10.5566/ias.v25.p43-53)
- [10] T. Roussillon, H. Piégay, I. Sivignon, L. Tougne, and F. Lavigne, "Automatic computation of pebble roundness using digital imagery and discrete geometry," *Comput. Geosci.*, vol. 35, no. 10, pp. 1992–2000, 2009. [doi: 10.1016/j.cageo.2009.01.013](https://doi.org/10.1016/j.cageo.2009.01.013)
- [11] J. Zhang, X. Yang, W. Li, S. Zhang, and Y. Jia, "Automatic detection of moisture damages in asphalt pavements from GPR data with deep CNN and IRS method," *Autom. Constr.*, vol. 113, no. September 2019, 2020. [doi: 10.1016/j.autcon.2020.103119](https://doi.org/10.1016/j.autcon.2020.103119)
- [12] L. Pei et al., "Pavement aggregate shape classification based on extreme gradient boosting," *Constr. Build. Mater.*, vol. 256, 2020.
- [13] K. A. Ghuzlan, M. T. Obaidat, and M. M. Alawneh, "Cellular-phone-based computer vision system to extract shape properties of coarse aggregate for asphalt mixtures," *Eng. Sci. Technol. an Int. J.*, vol. 22, no. 3, pp. 767–776, 2019. [doi: 10.1016/j.jestch.2019.02.003](https://doi.org/10.1016/j.jestch.2019.02.003)
- [14] J. Kim, B. S. Park, S. I. Woo, and Y. T. Choi, "Evaluation of ballasted-track condition based on aggregate-shape characterization," *Constr. Build. Mater.*, vol. 232, 2020. [doi: 10.1016/j.conbuildmat.2019.117082](https://doi.org/10.1016/j.conbuildmat.2019.117082)
- [15] O. J. Reyes-ortiz, M. Mejía, and J. S. Useche-Castelblanco, "Aggregate segmentation of asphaltic mixes using digital image," *Bull. Polish Acad. Sci. Tech. Sci.*, vol. 67, no. 2, pp. 279–287, 2019.
- [16] S. M. E. Harb, N. Ashidi, M. Isa, and S. A. Salamah, "Improved image magnification algorithm based on Otsu," *Comput. Electr. Eng. J.*, vol. 46, pp. 338–355, 2015.
- [17] J. V. C. I. R, C. Sha, J. Hou, and H. Cui, "A robust 2D Otsu 's thresholding method in image segmentation q," *J. Vis. Commun. Image R. J.*, vol. 41, pp. 339–351, 2016.

- [18] O. J. Reyes-Ortiz, M. Mejia, and J. S. Useche-Castelblanco, "Digital image analysis applied in asphalt mixtures for sieve size curve reconstruction and aggregate distribution homogeneity," *Int. J. Pavement Res. Technol.*, 2020. [doi: 10.1007/s42947-020-0315-6](https://doi.org/10.1007/s42947-020-0315-6)
- [19] S. Yu, S. Jia, and C. Xu, "Convolutional neural networks for hyperspectral image classification," *Neurocomputing*, vol. 219, pp. 88–98, 2017.
- [20] V. C. Janoo, "Quantification of shape, angularity, and surface texture of base course materials," 1998.
- [21] E. Masad, T. M. Al Rousan, J. Button, and D. Little, *Test Methods for Characterizing Aggregate Shape, Texture, and Angularity*. United States of America, 2007.
- [22] E. dos S. Silva et al., "Evaluation of macro and micronutrient elements content from soft drinks using principal component analysis and Kohonen self-organizing maps," *Food Chem.*, vol. 273, May 2018, pp. 9–14, 2019. [doi: 10.1016/j.foodchem.2018.06.021](https://doi.org/10.1016/j.foodchem.2018.06.021)
- [23] B. Yang, S. Yang, J. Zhang, and D. Li, "Optimizing random searches on three-dimensional lattices," *Phys. A Stat. Mech. its Appl.*, vol. 501, pp. 120–125, Jul. 2018. [doi: 10.1016/J.PHYSA.2018.02.100](https://doi.org/10.1016/J.PHYSA.2018.02.100)