



DETECCIÓN DE GRIETAS EN EL PAVIMENTO USANDO TÉCNICAS DE PROCESAMIENTO DE IMÁGENES Y REDES NEURONALES ARTIFICIALES

Lizette Tello Cifuentes, Johannio Marulanda, Peter Thomson

Universidad del Valle
Cali, Colombia

Resumen

La evaluación de la condición del pavimento es fundamental en los procesos de mantenimiento y rehabilitación. Los métodos de inspección que emplean imágenes, proporcionan información de la superficie del pavimento, permitiendo un análisis cuantitativo. Este artículo presenta una metodología para la detección de grietas en el pavimento, mediante la aplicación de técnicas de procesamientos de imágenes y redes neuronales artificiales; está dividido en cuatro etapas: i. Adquisición de las imágenes, ii. Procesamiento de imágenes, iii. Extracción de características y iv. Clasificación por medio de redes neuronales artificiales RNA. La metodología se aplicó en la detección de los tipos de deterioro: grieta longitudinal, bache y piel de cocodrilo. La clasificación se realizó mediante una red neuronal multicapa, la cual obtuvo una exactitud global de 95.56% y una precisión de 94.44%. El enfoque propuesto puede ser útil para las organizaciones gubernamentales e inspectores en la evaluación de la condición del pavimento.

Palabras clave: procesamiento de imágenes; redes neuronales artificiales; grietas en el pavimento

Abstract

The assessment of pavement conditions is essential in maintenance and rehabilitation processes. Inspection methods that use images, provide information on the surface of the pavement, allowing a quantitative analysis. This article presents a methodology for detecting cracks in the pavement, by applying artificial neural networks and image processing techniques; it is divided into four

stages: i. Acquisition of images, ii. Image processing, iii. Feature extraction and iv. Classification using artificial neural networks ANN. The methodology was applied in the detection of the types of deterioration: longitudinal crack, pothole, and alligator. The classification was performed using a multilayer neural network, which achieved an overall accuracy of 95.56% and a precision of 94.44%. The proposed approach can be useful for government organizations and inspectors in assessing pavement conditions.

Keywords: *image processing; artificial neural networks; pavement cracking*

1. Introducción

Los métodos tradicionales para la evaluación de la condición del pavimento, se basan en inspecciones visuales que se realizan por medio de personal especializado que recorre la vía y hace mediciones en sitio; estos métodos son subjetivos e implican altos costos de mano de obra. Avances recientes en tecnología, ofrecen nuevas metodologías que permiten analizar el comportamiento de la infraestructura vial, mediante la automatización del proceso de identificación (Kembhavi et al., 2020). Actualmente existen diferentes métodos para la evaluación del pavimento, como: manuales, métodos que emplean vibroacústica, radares de penetración, deflectómetros de impacto y métodos automáticos. El método manual es de lo más usados y depende de la experiencia del evaluador (Ragnoli et al., 2018). El vibroacústico detecta la variación estructural del pavimento, mediante el registro de la variación de la presión de aire dentro de una unidad de detección; donde la unidad de detección consta de un sensor con un micrófono contenido en un revestimiento aislante de ruido (Cafiso et al., 2020). Los radares de penetración emiten ondas electromagnéticas hacia el pavimento, y cualquier variación en la constante dieléctrica ocasionada por la detección de un nuevo material o una grieta, se verá reflejada en la señal de respuesta (Goulias et al., 2020). Los deflectómetros de impacto estiman la respuesta del pavimento midiendo la deflexión (Cafiso et al., 2020). Para el caso de los métodos automáticos, se incorporan diferentes sensores en un vehículo, con el cual se captura la información de la superficie del pavimento (Wu et al., 2019).

Entre los diferentes sistemas automáticos de adquisición de imágenes, se encuentra el PIAS, que captura información de la superficie del pavimento; y mediante el análisis de texturas con algoritmos multiresolución, identifican los deterioros en el pavimento (Moghadas Nejad & Zakeri, 2011). Ames Engineering creó un sistema de imágenes laser en 3D, el cual se adapta a un vehículo. Este captura datos del pavimento con una alta resolución (Zhou & Song, 2020). Otra forma de captura de la información son los vehículos aéreos no tripulados UAV. Los cuales emplean diferentes sensores para la adquisición de la información (Zhang & Elaksher, 2012). Estas tecnologías implican técnicas de procesamiento de imágenes, como (Pan et al., 2018) quien detectó grietas y baches en el pavimento; para ello las imágenes pasaron por una etapa de segmentación la cual se realizó por medio de variación de escala, para posteriormente realizar una extracción de características, mediante una combinación de características: como textura, geometría, y espectro. Para la clasificación, los algoritmos de aprendizaje automático proporcionan mejores resultados (Wang et al., 2019). Como (L. Li et al., 2014) que empleando técnicas de procesamiento de imágenes y redes neuronales artificiales para detección y



clasificación de grietas longitudinales y transversales. (Banharnsakun, 2017) identificó y clasificó grietas en el pavimento aplicando algoritmos de colonias de abejas y redes neuronales artificiales.

Este documento propone una metodología para la detección de grietas en el pavimento, empleado técnicas de procesamiento de imágenes y redes neuronales artificiales. La estructura del documento está organizada de la siguiente forma: sección 2, métodos, sección 3, resultados y la sección 4, conclusiones.

2. Metodología

La metodología para la detección y clasificación de fallas en el pavimento consta de cuatro etapas: i. Adquisición de las imágenes, ii. Procesamiento de las imágenes, iii. Extracción de características y iv. Clasificación del deterioro mediante RNA.

2.1 Adquisición de las imágenes

El dataset empleado en esta investigación, es de 300 imágenes adquiridas mediante dispositivo móvil, con diferentes resolución y variaciones de iluminación de los deterioros bache, piel de cocodrilo y grieta longitudinal. Se adquieren también imágenes provenientes del dataset SDNET2018 de la universidad Utah State (Maguire et al., 2018). El conjunto de imágenes se divide en 80% para entrenamiento, 240 imágenes y el 20% para validación 60 imágenes.

2.2 Procesamiento de imágenes

2.2.1 Preprocesamiento de la imagen

Las imágenes requieren de un preprocesamiento para mejorar el contraste y eliminar la distorsión. Las funciones de potencia permiten realizar una corrección del fondo de la imagen; ya que eliminan los efectos no uniformes de la intensidad en el fondo de la imagen, y de esta forma mejoran el contraste (L. Li et al., 2014; Ying & Salari, 2010).

2.2.2 Transformada Wavelet Scattering

La transformada Wavelet Scattering reduce la cantidad de información y la variabilidad entre las características; esta ha sido empleada en la discriminación de texturas, y es invariante a la rotación, traslación y cambio de escala. La transformada opera por medio de Wavelet en cascada. El cálculo de los coeficientes de primer orden se definen en (1) (Bruna & Mallat, 2011; Oyallon et al., 2013).

$$S_1 x = U_1 x \star \phi_j \quad (1)$$

$$U_1 x = (u, W_1) = |x \star \psi_{W_1}^1(u)| = |\sum_v x(u) \psi_{W_1}^1(u-v)| \quad (2)$$

Donde $U_1 x$ es el módulo de coeficientes Wavelet, ϕ_j es la función de escalamiento, y x la imagen de entrada (Oyallon et al., 2013).



$$\phi_j(u) = 2^{-2j}\phi(2^{-j}u) \quad (3)$$

$$\psi_{W_1}^1(u) = 2^{-2j_1}\psi^1(2^{-2j_1}r_{\theta_1}u) \quad (4)$$

Donde $\psi^1(u)$ es la Wavelet madre, es escalada por 2^{j_1} , j_1 es un entero o medio entero y esta rotado $\theta_1 = 2k\pi$ con $0 \leq k < K_1$ (Oyallon et al., 2013).

La transformada se emplea en las imágenes con la mejora de contraste, con el fin de resaltar características en la imagen; esta permite obtener una imagen de menor tamaño y con los bordes resaltados.

2.2.3 Detección de bordes

Los bordes son una de las características básicas más importante en la imagen. El borde está conformado por el conjunto de pixeles que presentan un cambio y reflejan discontinuidad (Jingyi Li et al., 2015). Entre los diferentes métodos para la detección de bordes, se encuentran el detector de bordes Prewitt y el Canny.

El detector de bordes Prewitt obtiene los bordes de la imagen mediante la convolución; y este opera por medio de filtros direccionales, los cuales son usados para calcular los bordes horizontales y verticales (Jingyi Li et al., 2015). El método de Canny aplica una convolución Gaussiana a la imagen para suavizarla, seguidamente calcula las discontinuidades de intensidad en la imagen, mediante la primera derivada; produciendo una intensidad de borde y dirección en cada pixel de la imagen suavizada (Hoang & Nguyen, 2018b; Muduli & Pati, 2013).

Debido a que no se logra detectar los bordes de las grietas por un mismo método; ya que el método de Canny identifica mejor la grieta longitudinal, y el método Prewitt los deterioros bache y piel de cocodrilo. Es necesario que las imágenes recorran el mismo proceso con los dos métodos de detección de bordes.

2.2.4 Matemática morfológica

La matemática morfológica modifica la forma de los objetos en la imagen, a través de la interacción con los objetos vecinos. Esta permite la reducción de ruido y la unión de fragmentos discontinuos producto de la detección de bordes. Entre las operaciones morfológicas básicas se encuentran la dilatación y erosión. La dilatación rellena los espacios vacíos, ya que unifica todos los elementos de la región vecina en uno; y la erosión elimina los pixeles vecinos, reduciendo el tamaño de los objetos (B. Li et al., 2011; Merazi-Meksen et al., 2014; Youquan et al., 2011).

A las imágenes con los bordes detectados se le realiza un relleno de espacio vacíos y eliminación de ruido. Estas se evalúan con diferentes umbrales, con el propósito de encontrar el umbral que mejor elimine el ruido. Dado que no se logra encontrar un solo umbral para los tres tipos de deterioro, se aplican el umbral de 250 para la grieta longitudinal, 800 para el bache y 200 para la piel de cocodrilo.



2.3 Extracción de características

La extracción de características es uno de los pasos más importantes en la clasificación, dado que tiene un impacto directo en el rendimiento del clasificador. Esta reduce la información y extrae las características más relevantes de los datos originales (Amin et al., 2015; Theodoridis & Koutroumbas, 2009). Los momentos invariante de Hu proporcionan información de la imagen, y son invariantes a la rotación, traslación y cambio de escala (Mohammed et al., 2017). La extracción de características se realiza por medio de los momentos invariantes de Hu. Se toman los primeros cuatro momentos dado que después del momento cinco no es posible discriminar entre las clases; por ello el vector de características de la imagen, está compuesto de concatenar los cuatro primeros momentos provenientes de las tres imágenes resultantes de la matemática morfológica, dando como resultado un vector de características de 12 dimensiones.

2.4 Clasificación

La clasificación de los diferentes deterioros, se realiza utilizando una red neuronal de tipo perceptrón multicapa, con algoritmo de aprendizajes Backpropagation (Choudhary & Dey, 2012). Para esto se utiliza el Toolbox de Matlab Neural Network.

3. Resultados

La metodología propuesta se realizó empleando imágenes de pavimento reales, capturadas con diferentes condiciones de iluminación y a diferentes resoluciones. Se obtienen también imágenes provenientes del dataset SDNET2018 del deterioro grieta longitudinal.

3.1 Procesamiento de imágenes

Las imágenes empleadas presentaban diferentes tamaños, por lo cual el tiempo de procesamiento varió según la dimensión de la imagen; este oscila entre 3.88 segundos para una imagen de 256x256 pixeles, y 3 minutos y 10 segundos, para una imagen de 4624x3468 pixeles. Este tiempo también estaba supeditado por las características de Hardware; empleándose un equipo con un procesador Intel Core I5, 8 gigabytes de memoria RAM y disco duro de 500 gigabytes. El tiempo lo determinó la transformada Wavelet Scattering que fue el proceso más demorado; esta transformada permitió resaltar el deterioro, dado que minimiza la diferencia dentro de un mismo tipo de textura y presenta discriminabilidad entre texturas, lo cual permite que los bordes se detecten mejor. En la Figura 1 se observa las imágenes obtenidas en cada una de las etapas del procesamiento.






Figura 1. Imágenes obtenidas en la etapa de procesamiento, para cada uno de los deterioros bache, piel de cocodrilo y grieta longitudinal. A. Imágenes con la mejora de contraste, B. Imágenes obtenidas de la transformada Scattering y C. Imágenes obtenidas posterior a la eliminación del ruido.

3.2 Clasificación RNA

Para la clasificación, se utilizó un dataset de entrenamiento compuesto de 80 imágenes para cada tipo de deterioro (bache, grieta longitudinal y piel de cocodrilo); y para la validación un dataset de 60 imágenes, 20 imágenes para cada tipo de deterioro.

Se realizaron 20 RNA, con variaciones en la capa oculta de 1 hasta 20. La capa de entrada fue creada con el vector de características resultante de los momentos invariantes de Hu; y la capa de salida está compuesta de 3 neuronas codificadas según el tipo de deterioro. De esto se escoge la red neuronal con configuración (12 14 3), 12 neuronas en la capa de entrada, 14 neuronas en la capa oculta y 3 neuronas en la capa de salida. Esta red no obtuvo el menor error medio cuadrático, pero su exactitud global fue mayor 95.56% y la precisión de 94.44%. Se calcularon también las métricas de desempeño sensibilidad, especificidad y F-score para cada una de las clases; obteniendo una sensibilidad del 100% para los deterioros piel de cocodrilo y grieta longitudinal, y para el bache del 80%, siendo este el deterioro que se confundió con la piel de cocodrilo (ver Tabla 1). La especificidad fue de 100% para los deterioros grieta longitudinal y bache, y 90% para la piel de cocodrilo; en el caso de la métrica de precisión F-score se obtuvo 0.88 para el bache, 0.90 para la piel de cocodrilo y 1 para la grieta longitudinal.



Tabla 1. Matriz de confusión para la RNA (12 14 3). Fuente: elaboración propia.

Deterioro	Bache	Piel de cocodrilo	Longitudinal
Bache	16	4	0
Piel de cocodrilo	0	20	0
Longitudinal	0	0	20

Para la clasificación de los deterioros se empleó una red neuronal MLP con algoritmo de aprendizaje Backpropagation y configuración (12 14 3), la cual obtuvo una exactitud global 95.56% y una precisión de 94.44%, confundiendo el deterioro bache con piel de cocodrilo. (Choudhary & Dey, 2012) clasificó empleando una RNA con algoritmo de aprendizaje Backpropagation y configuración (2 13 1) en la clasificación de imágenes con grietas y sin grietas, obteniendo una exactitud de 98.81% y una precisión de 90.08%. Por su parte (Lee & Lee, 2004) logró una exactitud en el clasificador de 95.2% en la clasificación de los deterioros tipo: grietas longitudinal, transversal, bloque, piel de cocodrilo y sin grieta. (Hoang & Nguyen, 2018a) obtuvo una exactitud de 84.25% en la clasificación de los deterioros grieta longitudinal, transversal, piel de cocodrilo y sin grieta.

4. Conclusiones

Se desarrolló una metodología para la detección de grietas en el pavimento, utilizando técnicas de procesamiento de imágenes y redes neuronales artificiales, para la detección de las fallas piel de cocodrilo, baches y grieta longitudinal. De esto se obtuvo una exactitud del clasificador 95.56% y una precisión del 94.44%, para una red neuronal MLP con configuración (12 14 3).

Se sugiere en trabajos futuros el análisis de otros deterioros como las grietas transversales, los bacheos y parcheos. También se pueden utilizar otras técnicas de procesamiento de imágenes que contribuyan a la detección de las grietas, cuando estas se encuentren en presencia de otros objetos.

5. Referencias

- Amin, H. U., Malik, A. S., Ahmad, R. F., Badruddin, N., Kamel, N., Hussain, M., & Chooi, W.-T. (2015). Feature extraction and classification for EEG signals using wavelet transform and machine learning techniques. *Australasian Physical & Engineering Sciences in Medicine*, 38(1), 139-149. <https://doi.org/10.1007/s13246-015-0333-x>
- Banharnsakun, A. (2017). Hybrid ABC-ANN for pavement surface distress detection and classification. *Int. J. Mach. Learn. & Cyber.*, 8(2), 699-710. <https://doi.org/10.1007/s13042-015-0471-1>
- Bruna, J., & Mallat, S. (2011). Classification with scattering operators. *CVPR 2011*, 1561-1566. <https://doi.org/10.1109/CVPR.2011.5995635>
- Cafiso, S., Di Graziano, A., Fedele, R., Marchetta, V., & Praticò, F. (2020). Sensor-based pavement diagnostic using acoustic signature for moduli estimation. *International Journal of Pavement Research and Technology*, 13(6), 573-580. <https://doi.org/10.1007/s42947-020-6007-4>



- Choudhary, G. K., & Dey, S. (2012). Crack detection in concrete surfaces using image processing, fuzzy logic, and neural networks. *2012 IEEE Fifth International Conference on Advanced Computational Intelligence (ICACI)*, 404-411. <https://doi.org/10.1109/ICACI.2012.6463195>
- Goulias, D. G., Cafiso, S., Di Graziano, A., Saremi, S. G., & Currao, V. (2020). Condition Assessment of Bridge Decks through Ground-Penetrating Radar in Bridge Management Systems. *Journal of Performance of Constructed Facilities*, 34(5), 04020100. [https://doi.org/10.1061/\(ASCE\)CF.1943-5509.0001507](https://doi.org/10.1061/(ASCE)CF.1943-5509.0001507)
- Hoang, N.-D., & Nguyen, Q.-L. (2018a). A novel method for asphalt pavement crack classification based on image processing and machine learning. *Engineering with Computers*, 35(2), 487-498. <https://doi.org/10.1007/s00366-018-0611-9>
- Hoang, N.-D., & Nguyen, Q.-L. (2018b). Metaheuristic Optimized Edge Detection for Recognition of Concrete Wall Cracks: A Comparative Study on the Performances of Roberts, Prewitt, Canny, and Sobel Algorithms. *Advances in Civil Engineering*, 2018, e7163580. <https://doi.org/10.1155/2018/7163580>
- Jingyi Li, Ning Wang, Ying Liu, & Yuemei Yang. (2015). A Study of Crack Detection Algorithm. *2015 Fifth International Conference on Instrumentation and Measurement, Computer, Communication and Control (IMCCC)*, 1184-1187. <https://doi.org/10.1109/IMCCC.2015.254>
- Kembhavi, K., Archana, M. R., & Anjaneyappa, V. (2020). *Low-Cost Image Processing System for Evaluating Pavement Surface Distress* (N.º 4372). Article 4372. <https://easychair.org/publications/preprint/87hn>
- Lee, B. J., & Lee, H. "David". (2004). Position-Invariant Neural Network for Digital Pavement Crack Analysis. *Computer-Aided Civil and Infrastructure Engineering*, 19(2), 105-118. <https://doi.org/10.1111/j.1467-8667.2004.00341.x>
- Li, B., Zhang, P., Wang, Z., Mi, S., & Zhang, Y. (2011). Gear fault detection using multi-scale morphological filters. *Measurement*, 44(10), 2078-2089. <https://doi.org/10.1016/j.measurement.2011.08.010>
- Li, L., Sun, L., Ning, G., & Tan, S. (2014). Automatic Pavement Crack Recognition Based on BP Neural Network. *Promet - Traffic&Transportation*, 26(1), 11-22.
- Maguire, M., Dorafshan, S., & Thomas, R. (2018). SDNET2018: A concrete crack image dataset for machine learning applications. *Browse all Datasets*. <https://doi.org/10.15142/T3TD19>
- Merazi-Meksen, T., Boudraa, M., & Boudraa, B. (2014). Mathematical morphology for TOFD image analysis and automatic crack detection. *Ultrasonics*, 54(6), 1642-1648. <https://doi.org/10.1016/j.ultras.2014.03.005>
- Moghadas Nejad, F., & Zakeri, H. (2011). A comparison of multi-resolution methods for detection and isolation of pavement distress. *Expert Systems with Applications*, 38(3), 2857-2872. <https://doi.org/10.1016/j.eswa.2010.08.079>
- Mohammed, A., al azzo, F., & Milanova, M. (2017). Classification of Alzheimer Disease based on Normalized Hu Moment Invariants and Multiclassifier. *International Journal of Advanced Computer Science and Applications*, 8. <https://doi.org/10.14569/IJACSA.2017.081102>
- Muduli, P. R., & Pati, U. C. (2013). A novel technique for wall crack detection using image fusion. *2013 International Conference on Computer Communication and Informatics*, 1-6. <https://doi.org/10.1109/ICCCI.2013.6466288>
- Oyallon, E., Mallat, S., & Sifre, L. (2013). *Generic Deep Networks with Wavelet Scattering*. <https://arxiv.org/abs/1312.5940v3>
- Pan, Y., Zhang, X., Cervone, G., & Yang, L. (2018). Detection of Asphalt Pavement Potholes and Cracks Based on the Unmanned Aerial Vehicle Multispectral Imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(10), 3701-3712. <https://doi.org/10.1109/JSTARS.2018.2865528>



- Ragnoli, A., De Blasiis, M. R., & Di Benedetto, A. (2018). Pavement Distress Detection Methods: A Review. *Infrastructures*, 3(4), 58. <https://doi.org/10.3390/infrastructures3040058>
- Theodoridis, S., & Koutroumbas, K. (2009). Chapter 7—Feature Generation II. En S. Theodoridis & K. Koutroumbas (Eds.), *Pattern Recognition (Fourth Edition)* (Fourth Edition, pp. 411-479). Academic Press. <https://doi.org/10.1016/B978-1-59749-272-0.50009-8>
- Wang, W., Wang, M., Li, H., Zhao, H., Wang, K., He, C., Wang, J., Zheng, S., & Chen, J. (2019). Pavement crack image acquisition methods and crack extraction algorithms: A review. *Journal of Traffic and Transportation Engineering (English Edition)*, 6(6), 535-556. <https://doi.org/10.1016/j.jtte.2019.10.001>
- Wu, S., Fang, J., Zheng, X., & Li, X. (2019). Sample and Structure-Guided Network for Road Crack Detection. *IEEE Access*, 7, 130032-130043. <https://doi.org/10.1109/ACCESS.2019.2940767>
- Ying, L., & Salari, E. (2010). Beamlet Transform-Based Technique for Pavement Crack Detection and Classification. *Computer-Aided Civil and Infrastructure Engineering*, 25(8), 572-580. <https://doi.org/10.1111/j.1467-8667.2010.00674.x>
- Youquan, H., Hanxing, Q., Jian, W., Wei, Z., & Jianfang, X. (2011). Studying of road crack image detection method based on the mathematical morphology. *2011 4th International Congress on Image and Signal Processing*, 2, 967-969. <https://doi.org/10.1109/CISP.2011.6100365>
- Zhang, C., & Elaksher, A. (2012). An Unmanned Aerial Vehicle-Based Imaging System for 3D Measurement of Unpaved Road Surface Distresses1. *Computer-Aided Civil and Infrastructure Engineering*, 27(2), 118-129. <https://doi.org/10.1111/j.1467-8667.2011.00727.x>
- Zhou, S., & Song, W. (2020). Robust Image-Based Surface Crack Detection Using Range Data. *Journal of Computing in Civil Engineering*, 34(2), 04019054. [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000873](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000873)

Sobre los autores

- Lizette Tello-Cifuentes: Ingeniera Topográfica, Especialista en Sistemas de Información Geográfica, Máster en Tecnologías de la Información Geográfica, Estudiante de Doctorado en Ingeniería de Universidad del Valle. Asistente de docencia. lizette.tello@correounivalle.edu.co
- Johannio Marulanda: Ingeniero Civil, Máster en Ingeniería Civil, Doctor en Ingeniería Civil de Universidad de Carolina del Sur. Profesor titular de Universidad del Valle. johannio.marulanda@correounivalle.edu.co
- Peter Thomson: Ingeniero Aeroespacial, Máster en Ciencias de la Ingeniería Aeroespacial, Doctor en Ingeniería Aeroespacial de Universidad de Minnesota. Profesor titular de Universidad del Valle. peter.thomson@correounivalle.edu.co

Los puntos de vista expresados en este artículo no reflejan necesariamente la opinión de la Asociación Colombiana de Facultades de Ingeniería.

Copyright © 2021 Asociación Colombiana de Facultades de Ingeniería (ACOFI)

