

## **Detección de grietas en concreto con histogramas de gradientes orientados**

Perla Lisseth Hernández Ortega<sup>1</sup>, Marco Cesar Salomón González<sup>1</sup>, Pedro Arguijo<sup>2</sup>,  
Roberto Ángel Meléndez Armenta<sup>2</sup>, José Antonio Hiram Vázquez López<sup>1</sup>

<sup>1</sup>Tecnológico Nacional de México,  
Instituto Tecnológico Superior de Misantla,  
División de Ingeniería en Sistemas Computacionales,  
México

<sup>2</sup>Tecnológico Nacional de México,  
Instituto Tecnológico Superior de Misantla,  
División de Estudios de Posgrado e Investigación,  
México

{182t0432, 182t0175, ramelendeza, jahvazquez1}@itsm.edu.mx,  
pedroarguijo16@gmail.com

**Resumen.** La identificación de grietas es un problema que requiere la participación humana y la identificación manual de las mismas. La detección temprana de grietas en las construcciones civiles, así como evaluación objetiva es de suma importancia para el mantenimiento de la misma pues éstas pueden indicar daños estructurales internos. En este trabajo se presenta un sistema de detección de grietas basado en un vector de características de HOG. La exactitud general del clasificador SVM, con las características extraídas, fue de un 98%. Este resultado indica que el enfoque propuesto puede detectar efectivamente grietas en las imágenes. Los resultados obtenidos son similares a los reportados previamente con métodos de aprendizaje profundo.

**Palabras clave:** Detección de grietas, HOG (Histograma de Gradientes Orientados), SVM.

### **Crack Detection in Concrete with Oriented Gradient Histograms**

**Abstract.** Crack identification is a problem that requires human participation and manual crack identification. The early detection of cracks in civil constructions, as well as an objective evaluation, is of utmost importance for their maintenance as they can indicate internal structural damage. In this paper, a crack detection

system based on a HOG feature vector is presented. The overall accuracy of the SVM classifier, with the extracted features, was 98%. This result indicates that the proposed approach can effectively detect cracks in images. The results obtained are similar to those previously reported with deep learning methods.

**Keywords:** Crack detection, HOG, SVM.

## 1. Introducción

El concreto u hormigón armado, es un material ampliamente utilizado en la construcción de edificios debido a su versatilidad, resistencia y bajo costo, convirtiéndose en uno de los materiales más empleados a nivel mundial [1].

Es de piedra formada de manera artificial a partir de áridos naturales (grava y arena) pegados por una pasta conglomerada hidráulica, principalmente cementos, adherida fuertemente a armaduras de acero, comúnmente varillas corrugadas de acero [2].

En la ingeniería civil, el concreto es usualmente utilizado para los trabajos de construcción debido a que posibilita la elaboración de múltiples estructuras resistentes a la compresión, a la tracción y a la flexión. De esta manera, si la elaboración de la estructura es adecuada, el material puede llegar a tener una duración permanente sin necesidad de contar con medidas de protección y conservación especiales, siempre y cuando las condiciones ambientales sean normales [2].

Las grietas y fisuras son una de las patologías más características y relevantes que afectan a las estructuras de hormigón armado como pavimentos, puentes, techos y paredes de túneles, por mencionar algunas. Estas son ocasionadas, entre otros factores, debido a tensiones que sobrepasan su capacidad de resistencia, a fluctuaciones de temperatura, al envejecimiento de la superficie e impactos ambientales.

Por su parte, las fisuras son daños superficiales de poca profundidad que no afectan estructuralmente a las construcciones; mientras que las grietas son daños con una profundidad considerable, llegando a cubrir hasta la totalidad del grosor de la estructura. Además, se consideran que son un indicador importante que refleja la degradación y el estado de seguridad de la infraestructura.

La expansión, contracción, sobrecarga, asentamiento o secado prematuro son causas comunes de grietas en la superficie de concreto. Las grietas pueden aparecer aisladas o como un grupo de varias grietas conectadas.

En el pavimento este tipo de deterioro se puede clasificar en función de varios parámetros, como su posición, su dirección y su forma [3, 4]. Su apariencia relativamente similar hace que los algoritmos de análisis de imágenes sean una herramienta ideal para su detección, lo cual conlleva a una prueba no destructiva.

La detección de grietas es el paso más importante durante la inspección, diagnóstico, mantenimiento y predicción de la vida útil de las estructuras civiles de concreto.

Además, reparar a tiempo las grietas evita daños mayores ya que el desarrollo y propagación de las grietas reduce primero la eficacia de una zona de carga, lo que aumenta la presión y, finalmente, daña la estructura [5].

El método convencional de detección de grietas se basa en inspectores capacitados que encuentran grietas en la superficie de una estructura de concreto, basándose en sus conocimientos y años de experiencia. Este método de detección de grietas no sólo requiere mucho tiempo y trabajo, sino que a menudo no es fiable porque los resultados dependen de la experiencia y la habilidad del inspector; lo que puede dar lugar a una supervisión o inspección inexacta [6, 7]. Para facilitar el progreso de la inspección visual, es necesario lograr la detección automática de grietas.

En comparación con el sistema tradicional de detección de grietas basado en la inspección visual, los enfoques basados en la visión artificial y el aprendizaje automático se están adoptando en la inspección de infraestructuras civiles para automatizar la detección e identificación de grietas [8-10]. Una revisión puntual de la detección de grietas basada en la visión artificial y la evaluación de los avances significativos de la infraestructura civil se encuentra en [11].

La detección de grietas de manera automática, permite entre otras cosas el ahorro de tiempo y personal, debido a que no se necesita que un inspector se traslade al terreno para identificar las grietas. Además, esto permite que la inspección se estandarice, es decir, que no existan dobles resultados de inspecciones de distintos inspectores.

Por otro lado, la automatización en la identificación de grietas permite la observación de grietas con acceso restringido o en lugares de difícil acceso, con el consiguiente ahorro económico.

Los métodos de aprendizaje profundo, específicamente las soluciones basadas en redes neuronales convolucionales (CNN), exhiben un rendimiento notable en el reconocimiento de dígitos, clasificación de imágenes, anotación de imágenes y otros campos relacionados. Las CNN son redes multicapa que aprenden, extraen y clasifican características automáticamente. Esto difiere de otros enfoques populares basados en la extracción de las características, como GLCM, Wavelets, LBP.

Inspirados en el rendimiento de los modelos de aprendizaje profundo, algunos estudios recientes han reportado el rendimiento de los modelos basados en CNN para la detección de grietas. Se han propuesto arquitecturas específicas y también se ha utilizado la transferencia de aprendizaje para la detección de las grietas [12-14]. Aunque no cabe duda de que las características profundas extraídas automáticamente a través de los CNN ofrecen una mejor capacidad de representación que las características extraídas de manera tradicional cabe preguntar, ¿se debe abandonar la extracción de características y utilizar únicamente las características profundas? Creemos es una pregunta significativa por diversas razones.

Previo a la adopción generalizada del aprendizaje profundo, la extracción de diversos conjuntos de características era un problema a resolver para la clasificación de imágenes. Aunque el proceso de extracción de características actúa como un puente vital entre la imagen sin procesar y la información discriminatoria de los vectores de características extraídos, la calidad de las características determina en gran medida la precisión de la clasificación.

Las características que funcionan bien en un entorno no son adecuadas en los demás. Consecuentemente, la selección de las características es especialmente importante. Por un lado, si se desea implementar una arquitectura de deep-learning desde cero, se debe disponer de una gran cantidad de datos para el entrenamiento de la misma.

Así mismo, al tener una arquitectura de deep-learning adecuada se puede caer en un ciclo de modificaciones de la misma para mejorar su rendimiento. Si se utiliza una arquitectura pre-entrenada como extractor de características cada una de las capas conectadas describe la imagen de entrada con un diferente nivel de abstracción, esto sin considerar la gran dimensionalidad del conjunto de datos.

En este trabajo, determinamos la presencia o no presencia de grietas en imágenes de concreto, en particular, consideramos el conjunto de datos públicos Concrete Crack Images for Classification [15]. Nuestro enfoque se basa en la extracción de características de Histogramas de Gradientes Orientados (HOG), como descriptor adecuado para la detección de grietas.

Se eligió HOG dado que, al operar en celdas locales, es invariable a transformaciones geométricas y fotométricas, y esto lo hace adecuado para la detección de grietas en pavimento. Además del vector de características, el clasificador tiene una gran influencia en el rendimiento de la detección de grietas.

En nuestro caso seleccionamos una máquina de soporte vectorial (SVM) debido a que está reportado en la literatura que esta combinación, HOG-SVM, tiene un buen desempeño en diversas tareas de clasificación. Cabe mencionar que se logró una alta exactitud de clasificación en la detección de las grietas. El clasificador se verificó con validación cruzada.

El documento está estructurado como se indica: los detalles del conjunto de datos utilizados, la extracción de características y el clasificador se dan en la siguiente sección. La sección 3 describe los resultados y se finaliza en la sección 4 con las conclusiones.

## **2. Materiales y métodos**

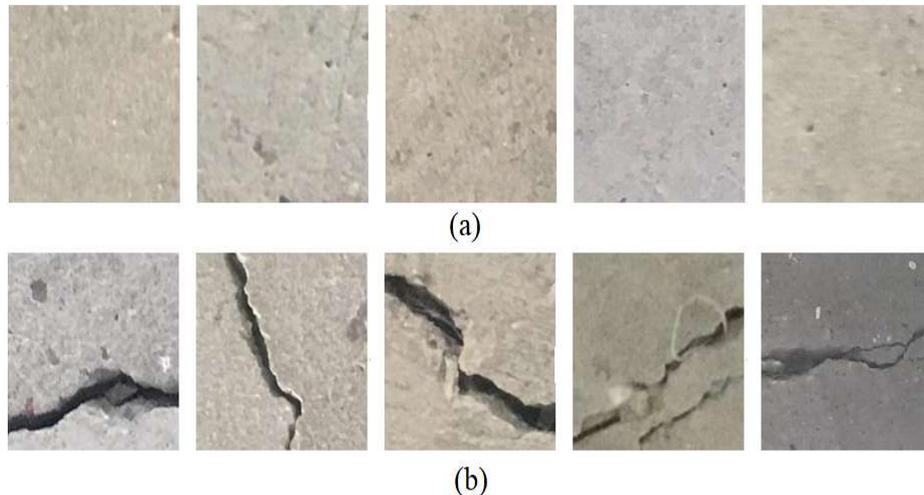
### **2.1. Conjunto de datos**

En estudios previos se han referenciado diversos conjuntos de datos (públicos y privados) para la detección automática de grietas en pavimentos [8-14]. La mayoría emplea conjuntos de datos no públicos, lo que complica establecer un punto de comparación entre las diversas metodologías propuestas.

Además, se debe considerar que en la creación de un conjunto de datos las imágenes deben tomarse de manera homogénea manteniendo condiciones constantes, tales como distancia, ángulo, etc. Por esta razón, en este trabajo utilizamos el conjunto de datos de código abierto de imágenes de grietas en concreto de la METU [15] para identificar la presencia o ausencia de grietas. Este conjunto de datos consta de un total de 40000 imágenes con una resolución de  $227 \times 227$  píxeles, que se dividen por igual en las clases con grietas y sin grietas.

Las imágenes se tomaron en ensayos estructurales de laboratorio bajo condiciones de iluminación casi uniformes.

La Figura 1 muestra un ejemplo del conjunto de datos utilizado. De dicho conjunto de datos se seleccionaron aleatoriamente 1000 imágenes con grietas y 1000 imágenes sin grietas.



**Fig. 1.** Muestra del conjunto de imágenes consideradas con diferentes condiciones de iluminación (a) sin grietas y (b) con grietas.

## **2.2. Histograma de gradientes orientados (HOG)**

La extracción de características es la parte más importante de cualquier sistema de reconocimiento. La transformación de los datos de entrada en un conjunto de características se denomina extracción de características.

Para este trabajo el Histograma de Gradientes Orientados (HOG, por sus siglas en inglés) [16] se consideró como el extractor de características para cada una de las imágenes seleccionadas.

Aunque inicialmente se propuso para la detección de peatones, se ha utilizado para diversos problemas de clasificación como detectar células humanas [17], en la detección de vehículos [18], así como en el reconocimiento facial [19].

HOG se basa en la suposición de que el aspecto local y la forma de un objeto pueden caracterizarse por la distribución de gradientes de intensidad local o direcciones de bordes, que por definición son perpendiculares a la dirección del gradiente.

En otras palabras, la distribución de los bordes, que están representados por los gradientes de intensidad, proporciona una caracterización de la forma sin un conocimiento directo de las posiciones de los bordes correspondientes. El proceso para obtener HOG de una imagen se muestra en la Figura 2.

Como se puede observar, se inicia calculando los gradientes de la imagen en las direcciones  $x$  e  $y$  sin suavizar. A continuación, la imagen se divide en una cuadrícula de bloques, cada uno de los cuales se divide en una cuadrícula de celdas.

Para cada píxel en la celda correspondiente, la orientación y magnitud se calculan en función de los gradientes de intensidad, y los histogramas orientados se votan con ponderación según las magnitudes de los gradientes.

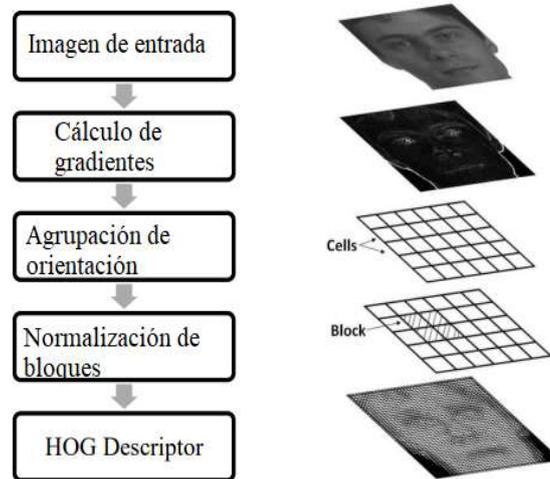


Fig. 2. Proceso de obtención del descriptor de características HOG.

Las frecuencias en los histogramas se normalizan en el intervalo  $[0, 1]$  para compensar los cambios en la iluminación. La combinación de los histogramas de todos esos bloques representa los descriptores HOG.

Para este trabajo, utilizamos seis contenedores de histogramas que almacenan las direcciones de los bordes y sus intensidades, para cada celda de  $8 \times 8$ . Con lo cual se obtienen 384 características por imagen.

### 2.3. Máquina de soporte vectorial

Las máquinas de soporte vectorial (SVM por sus siglas en inglés) pertenece al tipo de aprendizaje supervisado y se utiliza tanto para problemas de clasificación como de regresión. Es un sistema de aprendizaje que separa un conjunto de vectores de entrada en dos clases con un hiperplano de separación óptimo.

Se dice que el conjunto de vectores está separado de manera óptima, por el hiperplano, si está separado sin error y la distancia entre los vectores más cercanos al hiperplano es máxima.

El clasificador SVM se obtiene aplicando una variedad de funciones de núcleo, también conocido como kernel; lineal, polinomial, funciones de base radial, como posibles conjuntos de funciones de optimización.

Su base se encuentra en la solución de un problema de programación cuadrática dual y utilizando la minimización del riesgo estructural como principio inductivo, a diferencia de los algoritmos estadísticos clásicos que maximizan el valor absoluto de un error o de un error al cuadrado.

**Tabla 1.** Desempeño del modelo de clasificación considerando diversos valores de  $k$ .

<b>k</b>	<b>Exactitud</b>	<b>Precisión</b>	<b>Recall</b>
2	0.9855	0.9856	0.9855
4	0.9895	0.9895	0.9896
5	0.989	0.989	0.9891
8	0.9895	0.9895	0.9896
10	0.988	0.988	0.988

**Tabla 2.** Resultados de las métricas de evaluación con  $k = 10$ .

<b>Fold</b>	<b>Exactitud</b>	<b>Precisión (CG)</b>	<b>Precisión (SG)</b>	<b>Recall (CG)</b>	<b>Recall (SG)</b>
1	0.985	0.9815	0.9891	0.9906	0.9785
2	0.99	1	0.9809	0.9794	1
3	0.985	0.9811	0.9897	0.9905	0.9789
4	1	1	1	1	1
5	0.985	0.9794	0.9903	0.9896	0.9808
6	0.98	0.96	1	1	0.9615
7	0.985	0.9780	0.9908	0.9889	0.9818
8	0.99	0.9909	0.98889	0.9909	0.98889
9	0.985	0.9906	0.9787	0.9813	0.9892
10	0.995	1	0.9908	0.9899	1
Promedio	0.988	0.9861	0.9899	0.9900	0.9859

### 3. Resultados

El problema de la detección automática de grietas puede formularse como un problema de clasificación binaria que se resuelve clasificando las características de HOG con SVM. Con este fin y para asegurar el significado estadístico de los resultados y, además, verificar el desempeño del modelo se aplicó validación cruzada con  $k = 2$ , [4, 5, 8 y 10].

En la validación cruzada, los datos de entrenamiento se dividen aleatoriamente en  $k$  subconjuntos mutuamente excluyentes de aproximadamente el mismo tamaño. La regla de decisión se obtiene usando  $k-1$  de los subconjuntos y luego se prueba en el subconjunto que queda fuera. Este procedimiento se repite  $k$  veces y de esta manera cada subconjunto se usa para probar una vez. Promediar el error de prueba sobre los  $k$  intentos da una estimación del error de generalización esperado.

Las métricas consideradas para determinar la eficiencia del clasificador junto con las características de HOG fueron la precisión, el recall, la exactitud y f1-score. La precisión informa sobre las predicciones correctas realizadas a partir de falsos positivos, mientras que el recall informa sobre las predicciones precisas realizadas a partir de falsos negativos. La exactitud es el número de predicciones correctas entre los falsos positivos y los falsos negativos. Todas las métricas de rendimiento para los modelos entrenados se determinaron como se indica:

$$\begin{aligned} Precision &= \frac{TP}{TP + FP}, \\ Recall &= \frac{TP}{TP + FN}, \\ Accuracy &= \frac{TP + TN}{TP + TN + FN + FP}, \end{aligned}$$

donde TP son verdaderos positivos, TN son verdaderos negativos, FP son falsos positivos y FN son falsos negativos. Aquí, TP y TN son las predicciones correctas, mientras que FP y FN son las predicciones incorrectas realizadas por los modelos.

En la Tabla 1 se muestra los resultados promedios obtenidos para cada una de las métricas consideradas para los valores de  $k$  indicados. Como se puede apreciar los resultados son similares sin importar el número de  $k$ .

En la Tabla 2 se muestran los resultados de la validación cruzada con  $k = 10$ . La CG y SG tanto en la precisión como en el recall indican, con grieta y sin grieta, respectivamente. Como se puede observar, en el valor promedio, el método propuesto puede distinguir entre imágenes con grietas y sin grietas con una exactitud del 98%.

Nuestros resultados se comparan con resultados previamente reportados con el mismo dataset, pero haciendo uso de transferencia de aprendizaje a través de CNN pre-entrenadas [20]. Con estos resultados concluimos que la detección de grietas en concreto puede analizarse a través de la extracción tradicional de características en conjunto con un clasificador también tradicional. Obviamente, falta analizar el tipo y orientación de grietas, pero consideramos que si se incrementan el número de orientaciones en el contenedor esto es posible.

#### 4. Conclusiones y trabajo a futuro

En este trabajo se exploró el uso de características tradicionales, como lo es HOG, al problema de detección de grietas en imágenes de concreto; esto con la finalidad de utilizarlas en la inspección in situ de una infraestructura. La principal contribución de nuestro trabajo es el estudio y demostración de que las características de HOG son bastante robustas para determinar la presencia o ausencia de grietas. El tamaño vector considerado fue de 384 características por imagen, ya que se consideraron celdas de  $8 \times 8$  y seis orientaciones.

Los resultados demuestran que el enfoque propuesto, HOG-SVM, tiene una buena capacidad para discriminar entre la presencia y ausencia de grietas, con una exactitud, precisión y recall del 98%. Estos resultados son similares a los reportados previamente con métodos de aprendizaje profundo.

Aunque este documento se centra en las características de HOG y SVM como clasificador, creemos que, con investigación adicional, otras técnicas tradicionales de extracción de características pueden tener un papel importante en la detección de grietas. Esto conlleva varios desafíos y direcciones de investigación. Por ejemplo, se podría aplicar algoritmos de segmentación como fase adicional o paralela para determinar la longitud de las grietas.

También podrían emplearse otras técnicas de aprendizaje automático y esto daría un comparativo en la detección y probable tipo de grietas.

## Referencias

1. Serrano-González, L., Merino-Maldonado, D. A., Antolín-Rodríguez, P. C. Lemos, A. S. Pereira, P. Faria, A. Juan-Valdés, J. García-González, J. M. Morán-Del Pozo: Biotreatments using microbial mixed cultures with crude glycerol and waste pinewood as carbon sources: influence of application on the durability of recycled concrete. *Materials* 15/3, no. 1181 (2022) doi: 10.3390/ma1503118
2. Medina-Sánchez, E.: *Construcción de estructuras de hormigón armado en edificación*. Tercer Edición, Editorial Bellisco (2014)
3. Téllez Gutiérrez, R.: *Catálogo de deterioros en pavimentos flexibles de carreteras mexicanas*. Publicación Técnica no. 21 (1991) <https://imt.mx/archivos/Publicaciones/PublicacionTecnica/pt21.pdf>.
4. Consejo de directores de carreteras de Iberia e Iberoamérica, M5.1. Catálogo de deterioros de pavimentos flexibles, Colección de documentos, vol. no. 11 (2002) <https://sjnavarro.files.wordpress.com/2008/08/manualfallas.pdf>.
5. Bayar, G., Bilir, T.: A novel study for the estimation of crack propagation in concrete using machine learning algorithms. *Construction and building materials*, vol. 215, pp. 670–685 (2019) doi: 10.1016/j.conbuildmat.2019.04.227
6. Zhang, L., Shen, J., Zhu, B.: A research on an improved Unet-based concrete crack detection algorithm. *Structural Health Monitoring*, vol. 20 no. 4, pp. 1864–1879 (2021) doi:10.1177/1475921720940068
7. Koch, C., Georgieva, K., Kasireddy, V., Akinci, B., Fieguth, P.: A review on computer vision based defect detection and condition assessment of concrete and asphalt civil infrastructure. *Advanced engineering informatics*, vol. 29, no. 2, pp. 196–210 (2015) doi: 10.1016/j.aei.2015.01.008
8. Oliveira, H., Correia, P. L.: Automatic road crack detection and characterization. *IEEE Transactions on Intelligent Transportation Systems*, vol. 14, no. 1, pp. 155–168 (2013) doi: 10.1109/TITS.2012.2208630
9. Tang, J., Gu, Y.: Automatic crack detection and segmentation using a hybrid algorithm for road distress analysis. In: *IEEE International Conference on Systems, Man, and Cybernetics*, pp. 3026–3030 (2013) doi:10.1109/SMC.2013.516
10. Qingbo, Z.: Pavement crack detection algorithm based on image processing analysis. In: *8th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC)*, pp. 15–18 (2016) doi:10.1109/IHMSC.2016.96
11. Koch, C., Georgieva, K., Kasireddy, V., Akinci, B., Fieguth, P.: A review on computer vision-based defect detection and condition assessment of concrete and asphalt civil infrastructure. *Adv. Eng. Inform.*, vol. 29, no. 2, pp. 196–210 (2015) doi: 10.1016/j.aei.2015.01.008
12. Cha, Y. J., Choi, W., Büyüköztürk, O.: Deep learning-based crack damage detection using convolutional neural networks. *Computer-Aided Civil and Infrastructure Engineering*, vol. 32, no. 5, pp. 361–378 (2017) doi: 10.1111/mice.12263

13. Leal da Silva, W. R., Schwerz de Lucena, D.: Concrete cracks detection based on deep learning image classification. In: 18th International Conference on Experimental Mechanics (ICEM18), Proceedings, vol. 2, no. 8, pp. 489 (2018) doi: 10.3390/ICEM18-05387
14. Kim, B., Cho, S.: Automated vision-based detection of cracks on concrete surfaces using a deep learning technique. *Sensors*, vol. 18, no. 10, pp. 3452 (2018) doi: 10.3390/s18103452
15. Özgenel, Ç. F.: Concrete crack images for classification. *Mendeley Data* (2019) doi: 10.17632/5Y9WDSG2ZT.2
16. Dalal, N., Triggs, B.: Histograms of oriented gradients for human detection. In: IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), vol. 1, pp. 886–893, (2005) doi: 10.1109/CVPR.2005.177
17. Tikkanen, T., Ruusuvoori, P., Latonen, L., Huttunen, H.: Training based cell detection from bright-field microscope images. In: 9th International Symposium on Image and Signal Processing and Analysis (ISPA), pp. 160–164 (2015) doi: 10.1109/ISPA.2015.7306051
18. Laopracha, N., Sunat, K.: Comparative study of computational time that hog-based features used for vehicle detection. In: Recent Advances in Information and Communication Technology 2017. IC2IT 2017. Advances in Intelligent Systems and Computing, vol 566, (2018) doi: 10.1007/978-3-319-60663-7\_26
19. Carcagni, P., del Coco, M., Leo, M., Distante, C.: Facial expression recognition and histograms of oriented gradients: a comprehensive study. *SpringerPlus* 4, pp. 645 (2015) doi: 10.1186/s40064-015-1427-3
20. Özgenel, Ç. F., Sorguç, A. G.: Performance comparison of pretrained convolutional neural networks on crack detection in buildings. In: Proceedings of the 35th ISARC, pp. 693–700 (2018)