

DETECCIÓN DE BACHES Y SU SEVERIDAD USANDO EL VIDEO VBOX LITE Y TELÉFONOS INTELIGENTES

Detection of potholes and their severity using the Video VBOX Lite and smartphones

YASMANY GARCÍA-RAMÍREZ^a, FERNANDO GARCÍA^b,
VICENTE QUINCHE^c & WILMAN MAYGUA^d

Recibido: 6/2/2022 • Aprobado: 1/6/2022

Cómo citar: García-Ramírez, Y., García, F., Quinche, V., & Maygua, W. (2022). Detección de baches y su severidad usando el Video VBOX Lite y teléfonos inteligentes. *Ciencia, Ingenierías y Aplicaciones*, 5(1), 77–107. <https://doi.org/10.22206/cyap.2022.v5i1.pp77-107>

Resumen

Los baches son un problema común en pavimentos deteriorados. Estos desniveles disminuyen la comodidad de conducción y pueden llegar a causar siniestros viales. El geolocalizar los baches y su grado de severidad permitirán a los usuarios ajustar su velocidad y trayectoria en la vía deteriorada. Además, las entidades del Estado pueden planificar las intervenciones de mantenimiento en los sitios con más deterioro. Esto se podría resolver utilizando sensores como los que tienen los teléfonos celulares o el Video VBOX Lite, que tiene mayor precisión. La información recolectada por estos equipos por sí sola, no permite la geolocalización del bache o determinar su severidad; es necesario entender, procesar y evaluar esos datos para lograrlo. Por lo tanto, el objetivo de este estudio es proponer un procedimiento para detectar baches y su severidad usando el Video VBOX Lite y dos teléfonos inteligentes. Para

^a Profesor adjunto. Departamento de Ingeniería Civil, Universidad Técnica Particular de Loja (UTPL). Loja, Ecuador. ORCID: 0000-0002-0250-5155, Correo-e: ydgarcia1@utpl.edu.ec

^b Ingeniero civil. Departamento de Ingeniería Civil, Universidad Técnica Particular de Loja (UTPL). ORCID: 0000-0001-6616-2756, Correo-e: fdgarcia2@utpl.edu.ec

^c Ingeniero civil. Departamento de Ingeniería Civil, Universidad Técnica Particular de Loja (UTPL). ORCID: 0000-0002-1924-326X, Correo-e: vdquinche@utpl.edu.ec

^d Ingeniero civil. Departamento de Ingeniería Civil, Universidad Técnica Particular de Loja (UTPL). ORCID: 0000-0002-0086-9457, Correo-e: wamaygua@utpl.edu.ec



ello, la recolección de datos se hizo en dos fases. En la fase 1, se recolectaron los baches de manera manual (posición, profundidad y diámetro). Mientras que en la fase 2 se recolectaron los datos de los sensores de los equipos colocados en un vehículo liviano. Se circuló a velocidades entre 20 a 50 km/h. Basado en estos datos, se propuso dos procedimientos uno para el Video VBOX Lite y otro para los teléfonos celulares. La precisión de los procedimientos llegó a detectar entre 71-90 % de los baches. Este procedimiento se puede adaptar como crowdsourcing para generar datos de las redes viales locales.

Palabras clave: teléfono inteligente; seguridad vial; carretera; asfalto; política del transporte.

Abstract

Potholes are a common problem on deteriorated pavements. This difference in level reduces driving comfort and can lead to road accidents. Geolocating potholes and their severity will allow users to adjust their speed and trajectory on the damaged road. In addition, the government can plan maintenance interventions in the most deteriorated sites. This could be solved by using sensors like those found in smartphones or the Video VBOX Lite, which is more accurate. The information collected by these devices does not allow the geolocation of the pothole or determine its severity; it is necessary to understand, process, and evaluate this data to achieve it. Therefore, the objective of this study is to propose a procedure to detect potholes and their severity using the Video VBOX Lite and two smartphones. Data collection was done in two phases. In phase 1, potholes were collected manually (location, depth, and diameter). In phase 2, the device's sensors, placed in a vehicle, collected the data. The information was collected at speeds between 20 to 50 km/h. Based on these data, two procedures were proposed for the devices. The precision of the procedures detected between 71-90% of potholes. This procedure can be adapted as crowdsourcing to generate data from local road networks.

Keywords: smartphone; transport safety; road; asphalt; transport policy.

1. Introducción

En todo el mundo las redes viales son usadas ampliamente para transportar bienes y servicios. En ellas, los Estados invierten una gran cantidad de recursos para mantenerlas operativas la mayor parte del tiempo. Sin embargo, en algunas ocasiones, la red vial es tan grande que los gobiernos no alcanzan a mantenerlas, por lo que se inicia su deterioro. Uno de estos deterioros son los baches que se producen en pavimento flexible, los cuales pueden afectar el confort en la conducción, seguridad vial y las condiciones del vehículo (Fan, Ozgunalp et al., 2021). Una de las tareas más críticas en las redes viales es el monitorear la carretera para detectar este tipo de anomalías (S. Gupta et al., 2020).

Generalmente, la detección de baches la realizan ingenieros viales o inspectores calificados. Esta tarea, extremadamente laboriosa, consume una gran cantidad de tiempo y, a veces, es poco efectiva, dado que, dependiendo de las condiciones climáticas y del tránsito, el bache que se registra hoy, en pocos días, puede aumentar su severidad. Es por ello que se han buscado alternativas tecnológicas que permita detectar baches con el menor costo posible. Es así que, en la actualidad, existen tres enfoques principales para su detección: basados en vibración, basados en reconstrucción en 3D y métodos basados en visión (Arjapure & Kalbande, 2020).

Dentro de estos enfoques se han empleado varias técnicas: inteligencia artificial (Tithi et al., 2021; Yebes et al., 2021) y su subcampo aprendizaje de máquinas (Egaji et al., 2021; Kandoi et al., 2021; Shah et al., 2021; Yik et al., 2021), redes neuronales (Kempaiah et al., 2022; Rahman et al., 2022) tales como convolucional (Agrawal et al., 2021; Fan, Wang, et al., 2021; Kharel & Ahmed, 2022; S. S. Park et al., 2021; Patra et al., 2021; Pratama et al., 2021; Rahman et al., 2022), aprendizaje profundo (Bhavya et al., 2021; Kempaiah et al., 2022; Li & Liu, 2021; Shah et al., 2021) y visión por computadora (Camilleri & Gatt, 2020; Fan, Wang, et al., 2021; Kharel & Ahmed, 2022; Riedl et al., 2020), utilizando principalmente el procesamiento de imágenes computarizadas (Muhammad Hanif et al., 2020; Tithi et al., 2021; Wang, 2021). También se han utilizado videos (Javed et al., 2021; Tithi et al., 2021), imágenes térmicas

(S. Gupta et al., 2020), o imágenes aéreas (Han et al., 2020), imágenes de UAV (Becker1 et al., 2019), tecnología láser (Li & Liu, 2021; Ravi et al., 2020; Srivastava et al., 2020), tecnología LiDAR (J. S. Park et al., 2019; Ravi et al., 2020), análisis de agrupamiento (Fan, Ozgunalp, et al., 2021), entornos virtuales (Hu & Furukawa, 2020; Tsai et al., 2020), entre otros.

Para aplicar cualquier enfoque y el uso de la técnica es necesario recolectar información de la red vial. Esta recolección se ha hecho por medio de sensores a bordo vehículos o *scooters* (D. Gupta et al., 2021), sensores con GPS (Kempaiah et al., 2022; Pratama et al., 2021; Thakur et al., 2020), acelerómetros (Kempaiah et al., 2022; Kotha et al., 2020; Kumar et al., 2020; Yik et al., 2021), cámaras (Aswath et al., 2022; Muhammad Hanif et al., 2020; Pratama et al., 2021; Riedl et al., 2020; Tsai et al., 2020; Yik et al., 2021), estéreo cámara (Bangalore Ramaiah & Kundu, 2021), sensor ultrasónico (Arulananth et al., 2022; Ganesh Babu et al., 2020; Thakur et al., 2020), tabletas (Egaji et al., 2021), sensores móviles junto con sensores basados en imágenes (Kandoi et al., 2021), sensores de los teléfonos inteligentes (Ashwini et al., 2020; Kyriakou et al., 2019; Lekshmiathy et al., 2021; Mamatha et al., 2020; Ravi et al., 2020; Silvester et al., 2019; Thiruppathiraj et al., 2020; Van Khang & Renault, 2019), por citar algunos.

Como se puede ver, existe una gran cantidad de investigaciones sobre la detección de los baches. La selección del enfoque o la técnica condicionará los resultados e influirá en el costo de implementación. La utilización de los sensores de teléfonos inteligentes para detectar baches es muy llamativa, dado que este tipo de teléfonos se ha extendido ampliamente en el mundo y los usuarios pueden compartir esa información como un *crowdsourcing*. Sin embargo, es necesario entender la relación entre la información que recolecta el equipo con el bache (ubicación y severidad). En esta relación, los métodos que ofrecen mejores precisiones son los enfoques que usan las técnicas basadas en inteligencia artificial, pero estos pueden llegar a tener una gran demanda computacional. Es más, la precisión de detección de baches aún está lejos de ser satisfactoria (Fan et al., 2020), por lo que aún es necesario seguir explorando otros procedimientos.

En este contexto, el objetivo de este estudio es proponer un procedimiento para detectar baches y su severidad usando el Video VBOX Lite y dos teléfonos inteligentes: Samsung Galaxy S9 y Huawei P20. El estudio se realizó en una ciudad de Loja – Ecuador, de tal forma que puede servir para otras ciudades que tienen similares condiciones ambientales, constelación de satélites, cobertura de redes de teléfono celular, tipos de teléfonos disponibles en el mercado, entre otros. Para explicar los resultados de este estudio, el resto del artículo se organiza de la siguiente manera. En la sección 2 se muestran los materiales y métodos utilizados. En este apartado se detallan los tramos en donde se recolectaron los datos, las dos fases de recolección de datos y el procesamiento de datos. Luego, en la sección 3 se muestran los procedimientos que se proponen para detectar baches y su severidad para el Video VBOX Lite y los dos teléfonos celulares. En cada procedimiento se mencionan los filtros, umbrales y ecuaciones que se utilizan para llegar a detectar un bache (ubicación y severidad). Posteriormente, en la sección 4, se muestran los resultados de aplicación de los procedimientos, para luego después realizar la calibración con vías con condiciones similares. Finalmente, se discuten los resultados y se presentan las principales conclusiones.

2. Materiales y métodos

El objetivo del presente estudio es proponer un procedimiento para detectar baches y la severidad que pueden tener estos. Para ello, se eligieron los tramos viales del estudio, luego, se recolectaron datos manuales y después con los equipos seleccionados. Los primeros se procesaron para ubicar y clasificar su severidad, mientras que los datos de los equipos registraron las variaciones en los sensores que tienen instalados, y sirven para analizar su relación con los datos de recolección manual. Basado en estas dos fuentes de datos se propondrá un procedimiento para el Video VBOX Lite y otro para los teléfonos inteligentes.

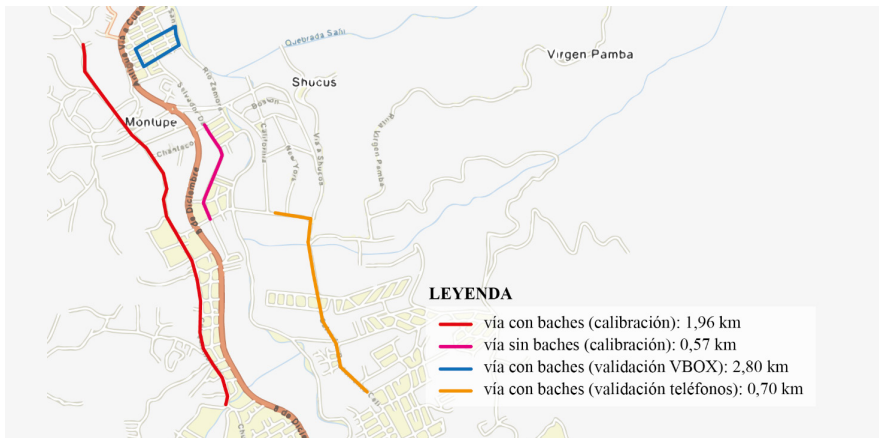
2.1 Tramos viales del estudio

Para la recolección de datos se eligieron dos tipos de tramos viales: para la calibración del procedimiento y para la validación del modelo (véase figura 1). Para la calibración se recolectaron dos tramos: uno en donde no existían baches y en otro donde existían baches. El tramo sin baches

sirvió para entender la variación de los sensores de los equipos cuando la vía no tiene esas anomalías, mientras que el tramo con baches sirvió para proponer el procedimiento. El resto de tramos viales sirvieron para validar el procedimiento que se plantea. Estos tramos viales corresponden a la ciudad de Loja (Ecuador).

Figura 1

Tramos de vía seleccionados para la recolección de datos en este estudio



2.2 Recolección de datos

2.2.1 Datos manuales

La recolección manual de los baches consistió en medir la posición, profundidad y diámetro de cada bache en todos los tramos de estudio. La posición fue recolectada con un navegador, mientras que la profundidad y diámetros fueron realizados con un flexómetro. También se tomaron fotos de cada bache recolectado.

2.2.2 Datos con los equipos

Antes de iniciar con la recolección de datos, se eligió al Kia Sportage 2006 como un vehículo de prueba. Este vehículo tuvo una revisión mecánica del sistema de suspensión para eliminar que los sensores detecten erróneamente un bache. Luego, se eligieron los equipos de recolección de datos: el Video VBOX Lite y los teléfonos celulares.

El Video VBOX Lite, previamente utilizado en estudios de velocidad, recolecta información de distancia, número de satélites, velocidad, azimut, latitud, longitud, altura, velocidad vertical, aceleración lateral, aceleración longitudinal, entre otros. El Video VBOX Lite tiene una antena GPS que se coloca en la parte superior del vehículo, lo cual asegura una precisión del 0,05 % por distancia recorrida, 0,2 km/h para la velocidad y ± 10 m para la altura. Este equipo tiene una frecuencia de muestreo de 10 Hz. Por otro lado, se eligieron los teléfonos: Samsung Galaxy S9 y el Huawei P20. Ambos poseen sensores GPS y acelerómetros y funcionan con sistema operativo Android. La precisión del GPS es de ± 6 m, mientras que la de la aceleración es $0,0024$ m/s² para el equipo Samsung y $0,0096$ m/s² para el equipo Huawei. En estos celulares se instaló la aplicación Physics Toolbox Suite® que permite recolectar la posición, tiempo, velocidad y aceleraciones con posibilidad de seleccionar la frecuencia de muestreo. En este estudio se seleccionó 10 Hz para los acelerómetros y 1 Hz para la posición.

Los equipos seleccionados fueron instalados dentro del vehículo de prueba. La antena GPS del Video VBOX Lite fue colocada en la parte superior del vehículo. Esta antena se conecta a un equipo donde recolecta la información. Este equipo y los teléfonos celulares se colocaron en el tablero del mando cerca del parabrisa frontal. Se tuvo cuidado de que la instalación no afectara la visión para una conducción segura. Los teléfonos y la consola del Video VBOX Lite fueron pegados al tablero con cinta adhesiva para que no se muevan durante la recolección de datos. En este tablero, ambos equipos se colocaron de manera horizontal. La recolección se realizó en el sentido de ida y de regreso. Las velocidades promedio del recorrido en los tramos de calibración fueron 20, 30, 40 y 50 km/h, mientras que en los de calibración fueron variables entre 20-50 km/h.

2.3 Procesamiento de datos

2.3.1 Datos manuales

Luego de haber recolectado los datos, estos fueron verificados para evitar errores, ya sea de tipeo, o en la recolección automática de la localización. Para ello, en la foto de cada bache se midió el diámetro del bache y se comparó con el registro manual. También, las coordenadas

de los baches fueron dibujadas en imágenes satelitales. Se corrigieron los errores o se volvió a registrar la posición de bache para tener una base de datos lista para realizar los siguientes análisis. Con los datos de diámetro y profundidad, y utilizando la tabla 1 (Shahin, 2006), se clasificaron los baches. En esta tabla también se han colocado unos ejemplos gráficos para ilustrar lo que se ha recolectado en este estudio.

Tabla 1

Clasificación de la severidad del bache con base en su diámetro y profundidad

Profundidad máxima (mm)	Diámetro promedio (mm)		
	102 - 203	203 - 457	457 - 762
12,7 – 25,4	Baja	Baja	Media
25,4 – 50,8	Baja	Media	Alta
> 50,8	Media	Media	Alta

Ejemplos
(A) Severidad
 baja: 30 mm
 (prof.) x 135 mm
 (diámetro)
(B) Severidad
 media: 60 mm
 (prof.) x 450 mm
 (diámetro)
(C) Severidad
 alta: 900 mm
 (prof.) x 550 mm
 (diámetro)



(A)



(B)



(C)

Nota. Propuesto por Shahin (2006).

2.3.2 Datos con los equipos

Los datos recolectados por el Video VBOX Lite fueron extraídos por el VBOX Test Suite®, mientras que los datos de los teléfonos celulares fueron extraídos mediante un *cvs que se genera en la aplicación. Los datos principales de ambos equipos fueron: coordenadas, la velocidad, las aceleraciones y el tiempo. En ambos casos, los datos se colocaron en una hoja electrónica para facilitar los cálculos. Los baches recolectados de manera

manual fueron emparejados con los datos recolectados con los sensores de los equipos. Con esta base de datos, se inició el proceso de calibración del procedimiento.

3. Procedimientos propuestos para detectar baches y su severidad

3.1 Precisión del procedimiento

Antes de iniciar con la descripción de los procedimientos, es necesario mencionar cómo se evaluará la eficacia de los mismos. Para ello se utilizarán tres conceptos: precisión, falsos positivos y falsos negativos. La precisión del procedimiento es la relación (en porcentaje) entre baches recolectados y los baches detectados por el procedimiento. Mientras más alto sea este valor, significará que el procedimiento detecta un mayor número de baches y viceversa. Por otro lado, los falsos positivos son aquellos baches que el procedimiento detecta, pero que en realidad no existen en el recorrido; en tanto que los falsos negativos son aquellos que el procedimiento no los detecta, pero que sí están presentes en el recorrido. En ambos casos, estos valores se relacionarán con los baches reales para determinar un porcentaje. Mientras más bajos sean estos valores, el procedimiento será más eficaz que otros que produce valores más altos.

3.2 Equipo Video VBOX Lite

El procedimiento para detección de baches y su severidad incluye una serie de filtros y umbrales para reducir y/o eliminar el ruido de los datos recolectados por los sensores del equipo. Las variables afectadas cuando se circuló por un bache fueron la aceleración vertical (z), aceleración lateral (x) y la velocidad del vehículo.

3.2.1 Aplicación del umbral de aceleración vertical (z) y aceleración lateral (x)

Para determinar el umbral aplicable a la aceleración vertical y lateral se siguió un procedimiento propuesto previamente (Harikrishnan & Gopi, 2017). La idea de este umbral es eliminar todos los valores que sean propios de la variabilidad de la recolección de los sensores del equipo en una calle con baches y otra sin ellos. Entonces, en la vía sin baches, se calculó el promedio de la aceleración lateral y el valor máximo de la

aceleración vertical. Se encontró un valor de $1,00 \text{ m/s}^2$ para la aceleración lateral y $0,31 \text{ m/s}^2$ para la aceleración vertical. Con estos datos se eliminaron todos los valores que tuvieron una aceleración lateral menor a $1,00 \text{ m/s}^2$ y una aceleración vertical menor a $0,31 \text{ m/s}^2$. Un ejemplo de la aplicación de estos umbrales se muestra en la figura 2.

3.2.2 Hacer más visibles las anomalías detectadas por medio de A_{zx}

Este paso tiene por objetivo que la base de datos resultante del paso anterior exagere sus valores, de tal forma de que sea más evidente la presencia de un bache. Para ello, se usó el producto Máx-Abs de Harikrishnan y Gopi (2017), que multiplica la aceleración lateral por la vertical. En este sentido, en primer lugar, se debe calcular el valor máximo de la aceleración lateral y vertical del proceso anterior, ocupando un ancho de ventana de 10 datos, lo que significa que se obtendrá este producto cada 1 segundo y no cada $0,1 \text{ s}$ que es la separación de la base de datos original. Con esto se obtiene una nueva base de datos mucho más pequeña que la anterior. Este producto se denominó A_{zx} y es adimensional. Un ejemplo de cálculo, a partir de los datos de la figura 2, se puede ver en la figura 3.

Figura 2

Ejemplos de aplicación del umbral de aceleración vertical (z) y aceleración lateral (x)

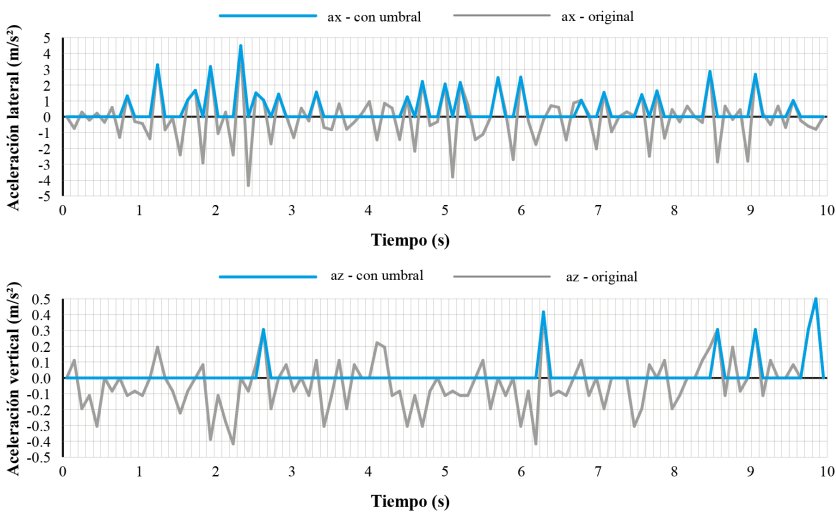



Figura 3

Ejemplos del cálculo de A_{zx} (producto de la aceleración vertical (z) y aceleración lateral (x))



3.2.3 Aplicación del umbral a A_{zx} basado en la velocidad

A pesar de contar con una base de datos reducida con la aplicación de los pasos anteriores, los datos aún presentan ruido debido a las velocidades de circulación del vehículo. Es entendible, que mientras más lento vaya el vehículo más tiempo tenga para que los sensores del equipo obtengan la información, en comparación a cuando un vehículo va a velocidades altas. Este paso se realizó con base en un estudio previo (Eriksson et al., 2008). Los umbrales basados en velocidad se obtienen por tanteos con base en la información reducida de las vías con baches. Para ello, se agruparon los recorridos en rangos de velocidades de 20 en 20 km/h. De esta agrupación, se eligieron los siguientes umbrales de A_{zx} : 0,60 para velocidades menores a 20 km/h, 0,75 para velocidades entre 20 y 40 km/h, y 0,90 para velocidades entre 40 y 60 km/h. Se probaron otros valores y diferente agrupación de velocidades, sin embargo, sus resultados fueron menos precisos que los presentados. Estos umbrales se aplican de la siguiente manera; si en un recorrido se circula a una velocidad menor a 20 km/h, los valores mayores a 0,6 en A_{zx} serán considerado como baches y los valores menores serán descartados. Se busca las coordenadas de los valores de A_{zx} que quedan, con lo que se obtiene su ubicación. Hay que considerar que como se utilizó un ancho de ventana de 1 segundo, este bache puede estar desplazado una cierta distancia que depende de la velocidad de circulación del vehículo.

3.2.4 Estimación de la severidad del bache

Como ya se vio previamente, los baches fueron clasificados de acuerdo a lo propuesto por Shahin (2006). Entonces, para estimar la severidad de los baches, con el Video VBOX Lite, se realizó un promedio de todos los baches (de la vía con baches) clasificados según la severidad y velocidad de circulación, cuyo resultado se muestra en la tabla 2. El valor resultante de Azx se compara con el promedio \pm el intervalo de confianza ($IC_{95\%}$) de la tabla 2. Si este está dentro de este rango, entonces se caracteriza y se le asigna una severidad. En la tabla 2, además del promedio, también se colocaron otros estadísticos del Azx para entender la variabilidad de los datos. No fue posible determinar valores para severidad baja debido a que no hubo en este recorrido. De todas formas, los baches de severidad baja son menos peligrosos para los conductores.

Tabla 2

Estadísticos relacionados con la severidad de bache para el Video VBOX Lite con base a los valores Azx para las vías de la calibración

Estadísticos	Rango de velocidad de circulación y Azx								
	< 20 km/h, Azx > 0,60			20 – 40 km/h, Azx > 0,75			40 – 60 km/h, Azx > 0,90		
Severidad	Alta	Media	Baja	Alta	Media	Baja	Alta	Media	Baja
Número de datos	22	18	-	32	33	-	7	12	-
Azx promedio	1,25	0,95	-	1,61	1,27	-	1,41	1,54	-
Azx máximo	2,95	1,26	-	4,65	2,07	-	2,29	3,04	-
Azx mínimo	0,64	0,62	-	0,78	0,75	-	0,90	0,95	-
STD Azx	0,62	0,19	-	0,87	0,36	-	0,51	0,62	-
IC (95%) Azx	$\pm 0,22$	$\pm 0,07$	-	$\pm 0,25$	$\pm 0,10$	-	$\pm 0,31$	$\pm 0,29$	-

En la tabla 2 se puede ver que en los rangos de velocidades hasta 40 km/h, las severidades altas les corresponden valores más altos y decrecen conforme disminuye la severidad. Esto no ocurre en el rango de 40-60 km/h, lo cual se debe al bajo número de datos en esos umbrales. Esto podría validarse o ajustarse en futuras investigaciones con velocidades de circulación mayores a 40 km/h. Para estimar la severidad del

bache para otras vías no se puede usar directamente los estadísticos de la tabla 2, por lo que se propuso la tabla 3, basada en el A_{zx} promedio y el intervalo de confianza, con ligeros ajustes. Con estos umbrales, incluso se pueden clasificar los baches de severidad baja hasta una velocidad de 40 km/h, ya que luego de ese valor los resultados fueron inconsistentes.

Tabla 3

Umbrales propuestos para Video VBOX Lite para estimar la severidad de un bache basado en los valores A_{zx} para las vías de la calibración

Umbrales	Rango de velocidad de circulación y A_{zx}								
	< 20 km/h, $A_{zx} > 0,60$			20 – 40 km/h, $A_{zx} > 0,75$			40 – 60 km/h, $A_{zx} > 0,90$		
Severidad	Alta	Media	Baja	Alta	Media	Baja	Alta	Media	Baja
Umbrales	\geq	1,03 –	\leq	\geq	1,37 –	\leq	-	-	-
A_{zx}	1,03	0,87	0,87	1,37	1,17	1,17	-	-	-

3.3 Teléfonos inteligentes

No fue posible seguir el mismo procedimiento del Video VBOX Lite, dado que los datos que se reciben en los teléfonos inteligentes son más limitados y su precisión difiere. Los teléfonos al tener integrado el GPS dentro del equipo tendrá una precisión menor que el Video VBOX Lite, dado que este tiene la antena GPS colocada por sobre el vehículo. Con esta ubicación se eliminan interferencias que dentro del vehículo se pueden encontrar. A pesar de esta limitación, se logró presentar un procedimiento que incluye: una reorientación virtual, filtro para velocidad cero, filtro relacionado con el ruido de baja frecuencia, un suavizado y umbrales para la aceleración vertical.

3.3.1 Reorientación virtual del teléfono inteligente

Para que la recolección de datos de un teléfono inteligente sea información que se relacione con el vehículo en donde está instalado, sus ejes deben estar alineados con los ejes del vehículo. Esto se produce cuando el teléfono ubicado de manera perfectamente horizontal y su eje longitudinal coincide con el del vehículo. En la práctica, es difícil de lograrlo, dado que

en el tablero del vehículo no existen superficies planas y, muchas veces, los teléfonos se colocan de manera vertical. Entonces, para corregir la colocación del vehículo, los datos recolectados deben reorientarse virtualmente, utilizando el método de ángulos de Euler (Singh et al., 2017).

Para esta reorientación, en primer lugar, se calculan los ángulos de orientación α y β , en función del registro del acelerómetro: aceleración lateral (a_x), aceleración longitudinal (a_y) y aceleración vertical (a_z), con las siguientes ecuaciones:

$$\alpha = \tan^{-1} \left(\frac{a_y}{a_z} \right) \quad (1)$$

$$\beta = \tan^{-1} \left(\frac{-a_x}{\sqrt{a_y^2 + a_z^2}} \right) \quad (2)$$

Posteriormente, se calculan las aceleraciones reorientadas (a'_x , a'_y , a'_z) en cada uno de los ejes, mediante las siguientes expresiones matemáticas:

$$a'_x = \cos(\beta) a_x + \sin(\beta) \sin(\alpha) a_y + \cos(\alpha) \sin(\beta) a_z \quad (3)$$

$$a'_y = \cos(\alpha) a_y - \sin(\alpha) a_z \quad (4)$$

$$a'_z = -\sin(\beta) a_x + \cos(\beta) \sin(\alpha) a_y + \cos(\beta) \cos(\alpha) a_z \quad (5)$$

Entonces, toda la base de datos se corrige con el uso de las ecuaciones 1-5. De los resultados experimentales, las aceleraciones verticales son las que más se afectan con las depresiones en las calles, por lo tanto, el resto del procedimiento se concentra en esta aceleración.

3.3.2 Filtro con velocidad cero

Cuando el vehículo está estacionado, el teléfono inteligente sigue registrando información, debido, principalmente, a las vibraciones del motor, mas no a la presencia de un bache, por lo tanto, el siguiente paso fue eliminar todos los registros en donde el vehículo tuvo velocidad

cero. Esta eliminación permite una demanda computacional más baja y, además, permite visualizar más fácilmente las tendencias de la aceleración y muy útil si se desea detectar baches utilizando aplicaciones de teléfono celular.

3.3.3 Filtro relacionado con el ruido de baja frecuencia

Asimismo, se debe considerar que la información de baja frecuencia, relacionada con bajas velocidades, también genera ruido en los datos recolectados. En un estudio anterior (Vittorio et al., 2014) se considera una velocidad de 5 km/h como valor de referencia y se usan las siguientes condiciones:

$$a_{z-5 \text{ km/h}} = \begin{cases} 0 & \text{si } a'_z \leq a'_{z-\text{máx-5km/h}} \\ a'_z - a'_{z-\text{máx-5km/h}} & \text{si } a'_z > a'_{z-\text{máx-5km/h}} \end{cases} \quad (6)$$

Donde: $a_{z-5 \text{ km/h}}$ es la aceleración vertical luego de aplicar el filtro de los 5 km/h, a'_z es la aceleración vertical reorientada, y $a'_{z-\text{máx-5 km/h}}$ es el valor máximo de la aceleración vertical reorientada cuando el vehículo transita a una velocidad de 5 km/h.

El valor de $a_{z-\text{máx-5 km/h}}$ no es un valor fijo y dependerá de los datos recolectados. Luego de aplicar las expresiones previas se elimina la información de baja frecuencia.

3.3.4 Suavizado en la aceleración vertical

En los teléfonos inteligentes, la aceleración vertical es la variable que más varía cuando se circula sobre un bache; sin embargo, presenta, por diversos motivos, aún ruido en sus datos. Por lo tanto, se aplica un nuevo paso que suaviza los datos. Esta suavización, normalizado al eje vertical (z) (Pawar et al., 2020), se realiza con la siguiente ecuación:

$$a_{zi-sua} = \frac{(a_{z-5\text{km/h-i}} - a_{z-5\text{km/h-prom}})}{a_{z-5\text{km/h-STD}}} \quad (7)$$


Donde: $a_{z\text{-sua}}$ = aceleración vertical suavizada, $a_{z\text{-5km/h-i}}$ = aceleración vertical luego de aplicar el filtro de los 5 km/h, $a_{z\text{-5km/h-prom}}$ = valor promedio de la aceleración vertical luego de aplicar el filtro de los 5 km/h, $a_{z\text{-5km/h-STD}}$ = desviación estándar aceleración vertical luego de aplicar el filtro de los 5 km/h.

3.3.5 Umbral final de la aceleración vertical

Finalmente, se aplica un umbral a la aceleración vertical suavizada denominado DVA. Se adoptó un valor de 3 m/s^2 (Vittorio et al., 2014) como umbral. Solo cuando el valor $a'_{z\text{-sua}}$ exceda ese valor, entonces, se considerará como bache. Un ejemplo del cálculo de DVA, así como todos los pasos anteriores del procedimiento, se puede ver en la figura 4. A cada fila de la base de datos final le corresponde unas coordenadas, por lo tanto, con esto ya se podrá localizar el bache.

Figura 4

Ejemplos de los resultados DVA y los pasos previos en el procedimiento de teléfonos inteligentes



3.3.6 Estimación de la severidad del bache

A fin de estimar la severidad del bache, se propone la tabla 4 para los dos teléfonos inteligentes. En esta tabla se han colocado varios estadísticos saltos corresponden a severidades altas, y cuando se reduce el valor de DVA la severidad disminuye. Esto se aplica a ambos teléfonos, sin embargo, los valores no son los mismos. Generalmente, la desviación estándar del teléfono Samsung es más alta que el Huawei. Esto se debe al

tipo de sensores que tienen los teléfonos, dado que están utilizando la misma aplicación de recolección, mismo día, mismo sitio y misma posición del teléfono.

Tabla 4

Estadísticos relacionados con la severidad de bache para los teléfonos inteligente con base en los valores DVA para las vías de la calibración

Estadísticos	Tipo de teléfono inteligente					
	Samsung Galaxy S9			Huawei P20		
Severidad	Alta	Media	Baja	Alta	Media	Baja
Número de datos	8	8	7	15	20	3
DVA promedio	8,81	6,26	3,56	5,86	4,52	3,68
DVA máximo	11,05	7,81	3,82	6,92	5,65	3,45
DVA mínimo	6,92	4,96	3,34	5,12	3,68	3,87
STD DVA	1,37	1,07	0,20	0,54	0,56	0,20
IC (95%) DVA	±0,95	±0,74	±0,15	±1,00	±1,00	±0,40

Los datos de la tabla 4 no se pueden usar directamente para determinar la severidad de baches en otras vías, por lo tanto, se proponen umbrales de DVA, basados en su promedio y en su intervalo de confianza, cuyo error fue distribuido entre tipo de severidad. Su resultado se muestra en la tabla 5.

Tabla 5

Umbrales propuestos para teléfonos inteligentes para estimar la severidad de un bache basado en los valores DVA para las vías de la calibración

Umbrales	Tipo de teléfono inteligente					
	Samsung Galaxy S9			Huawei P20		
Severidad	Alta	Media	Baja	Alta	Media	Baja
Umbral DVA	≥ 6,22	6,22 - 4,10	≤ 4,10	≥ 3,69	3,69 - 2,52	≤ 2,52

4. Resultados

4.1 Equipo Video VBOX Lite

El procedimiento VBOX, descrito previamente, fue aplicado a la vía de la calibración y cuyo resultado se muestra en la tabla 6. En esta tabla se ha colocado el sentido de circulación (ida y vuelta) y la velocidad promedio del recorrido. Como se puede ver, la precisión de este procedimiento está entre 71-84 %, mientras que los falsos negativos entre 9-29 % y los falsos positivos entre 3-23 %.

Tabla 6

Resultados del procedimiento planteado para el equipo Video VBOX Lite para las vías de la calibración

Velocidad promedio (km/h)	Sentido de ida			Sentido de vuelta		
	Falsos negativos (%)	Falsos positivos (%)	Precisión (%)	Falsos negativos (%)	Falsos positivos (%)	Precisión (%)
20	29	18	71	16	16	84
30	29	10	71	26	9	74
40	29	3	71	26	23	74
50	23	11	77	23	9	77

El procedimiento fue validado en los otros recorridos realizados, cuyo resultado se muestra en la tabla 7. En este caso, la precisión del procedimiento estuvo entre el 72-84 %, resultado muy parecido al anterior. Los falsos negativos estuvieron entre 16 a 17 %, mientras que los falsos positivos estuvieron entre 22-26 %. Estos resultados también son similares a los previos, por lo que se pueden considerar como un procedimiento válido.

Tabla 7

Resultados del procedimiento planteado para el equipo Video VBOX Lite para las vías de validación

Velocidades del recorrido	Baches reales	Baches detectados	Falsos negativos (%)	Falsos positivos (%)	Precisión (%)
20 – 50	18	15	17	24	83
20 – 50	18	13	28	22	72
20 – 50	19	16	16	26	84

Por otro lado, los umbrales para clasificar al bache también fueron calculados en las vías de validación. Estos resultados se pueden ver al final de la tabla 8. No fue posible calcular en todos los rangos de velocidad o severidad, debido a que estas vías no poseen todos los rangos que se tuvieron en la calibración. Como se puede ver en la tabla 8, los resultados son bastante parecidos a los calibrados en la 3, por lo tanto, también se pueden considerar como válidos.

Tabla 8

Estadísticos relacionados con la severidad de bache para el Video VBOX Lite con base a los valores Azx para las vías de validación

Estadísticos	Rango de velocidad de circulación y Azx								
	< 20 km/h, Azx > 0,60			20 – 40 km/h, Azx > 0,75			40 – 60 km/h, Azx > 0,90		
Severidad	Alta	Media	Baja	Alta	Media	Baja	Alta	Media	Baja
Número de datos	10	-	-	11	7	2	-	-	-
Azx promedio	1,47	-	-	1,59	1,22	1,3	-	-	-
Azx máximo	2,88	-	-	2,97	2,78	1,33	-	-	-
Azx mínimo	0,62	-	-	0,86	0,87	1,26	-	-	-
STD Azx	0,67	-	-	0,67	0,69	0,05	-	-	-
IC (95%) Azx	±0,35	-	-	±0,33	±0,43	±0,06	-	-	-
Umbrales Azx	≥ 1,12	-	-	≥ 1,46	1,46 – 1,08	≤ 1,08	-	-	-

4.2 Teléfonos inteligentes

Asimismo, el procedimiento para detectar los teléfonos inteligentes también aplicado a la vía de calibración y validación. El primer resultado se puede ver en la tabla 9. La precisión del teléfono Samsung Galaxy S9 está entre 71-84 %, los falsos negativos entre 7 y 24 % y los falsos positivos entre 7 y 18 %. Estos valores están muy cercanos a los obtenidos con el Video VBOX Lite. Por otro lado, para el teléfono Huawei P20, la precisión está entre el 72-90 %, los falsos negativos están entre 13-34 %, y los falsos positivos entre 7-39 %. A pesar de que con el Huawei se obtienen mejores precisiones, por otro lado, se aumentan los resultados falsos, lo cual es negativo para la eficacia del procedimiento.

Tabla 9

Resultados del procedimiento planteado para los teléfonos inteligentes para las vías de la calibración

Velocidad promedio (km/h)	Sentido de ida			Sentido de vuelta		
	Falsos negativos (%)	Falsos positivos (%)	Precisión (%)	Falsos negativos (%)	Falsos positivos (%)	Precisión (%)
Samsung Galaxy S9						
20	16	18	84	22	8	78
30	21	13	77	29	8	71
40	16	11	82	21	7	79
50	24	7	76	21	15	77
Huawei P20						
20	14	10	90	21	19	83
30	23	26	81	34	7	72
40	13	24	89	22	39	82
50	24	20	80	18	36	85

El procedimiento fue validado con otro recorrido, y cuyo resultado se ve en la tabla 10. La precisión de ambos teléfonos estuvo entre 79-100 %, los falsos negativos entre 0-20 % y los falsos positivos entre 7-22 %. Con estos resultados también se puede decir que el procedimiento es válido.

Tabla 10

Resultados del procedimiento planteado para los teléfonos inteligentes para las vías de validación

Velocidades del recorrido	Baches reales	Baches detectados	Falsos negativos (%)	Falsos positivos (%)	Precisión (%)
Samsung Galaxy S9					
20 - 50	29	23	17	7	79
20 - 50	29	23	20	17	79
Huawei P20					
20 - 50	25	25	0	19	100
20 - 50	26	23	0	22	88

En lo que se refiere a los umbrales para clasificar el bache, también fueron calculados en las vías de validación (véase final de la tabla 11). En este caso, debido a la cantidad de datos que se tienen en la severidad media, los umbrales varían, especialmente, para el teléfono Huawei P20. En el caso del teléfono Samsung, las diferencias son menores, por lo tanto, se podrían considerar como aceptables para este equipo. En el caso de Huawei P20 se debería profundizar esta variación en estudios posteriores.

Tabla 11

Estadísticos relacionados con la severidad de bache para los teléfonos inteligente con base en los valores DVA para las vías de validación

Estadísticos	Tipo de teléfono inteligente					
	Samsung Galaxy S9			Huawei P20		
Severidad	Alta	Media	Baja	Alta	Media	-
Número de datos	19	6	-	19	5	-
DVA promedio	8,72	6,31	-	7,58	4,91	-
DVA máximo	14,45	7,51	-	11,4	6,3	-
DVA mínimo	5,28	5,18	-	4,81	3,86	-
STD DVA	2,55	0,95	-	1,41	0,52	-
IC (95%) DVA	±1,15	±0,76	-	±0,65	±0,45	-
Umbrales DVA	≥ 7,34	7,34 – 5,55	≤ 5,55	≥ 6,15	6,15 – 4,48	≤ 4,48

5. Discusión

El presente estudio presentó dos metodologías para detectar baches y su severidad para equipos basados en vibración. La precisión alcanzada en estos procedimientos fue entre 71-90 %. Estudios previos alcanzaron una precisión en la detección del 75 % (Yebe et al., 2021), 80 % (Kempaiyah et al., 2022), 84 % (Bangalore Ramaiah & Kundu, 2021), 88 % (Pundir et al., 2021), 90 % (Kyriakou et al., 2019), por citar algunos. Los resultados de este estudio, comparado con los resultados son bastante aceptables. Sin embargo, si se los compara con estudios basados con otro enfoque o combinación de técnicas de procesamiento de información, como inteligencia artificial, esta precisión aumenta considerablemente: 93,18 % (Lekshmiathy et al., 2021), 95,2 % (Chen et al., 2020), 97,6 % (Patra et al., 2021), 98,1 % (Aswath et al., 2022), 98,7 % (Fan et al., 2020), 99,6 % (Fan et al., 2020), incluso, algunos pocos han llegado al 100 % de detección. Desafortunadamente, para lograr estos valores de precisión es necesario mayores recursos, ya sea en adquirir equipos, personal calificado, mayor demanda computacional, etc., que algunos gobiernos no están dispuestos a invertir. El procedimiento que se plantea es una muy buena primera experiencia, dado que en Latinoamérica no se conoce de estudios similares.

6. Conclusiones

Este estudio tuvo por objetivo proponer un procedimiento para detectar baches y su severidad usando el Video VBOX Lite y dos teléfonos inteligentes: Samsung Galaxy S9 y Huawei P20. Los equipos se colocaron dentro de un vehículo de prueba, y cuyos sensores recolectaron, mediante vibración o GPS, la aceleración en los tres ejes, la velocidad del vehículo, entre otros. A partir del análisis de estos resultados se presentan las principales conclusiones.

Los procedimientos para el Video VBOX Lite y Samsung S9, a pesar de ser diferentes, dan resultados consistentes en los recorridos de calibración y los de validación. Esto los hace más confiables a la hora de usarlos en recolección de datos masiva. Es evidente que el equipo VBOX, aunque sea más preciso, no será adquirido por los usuarios. Sin embargo, los resul-

tados del Samsung S9 son similares a los del Video VBOX Lite, por lo que este teléfono se puede utilizar con más confianza en la detección de baches y clasificación de su severidad. Esto no sucede con el equipo Huawei que obtuvo resultados más diversos entre recorridos y sus valores fueron diferentes a los del otro equipo celular y al VBOX Lite.

Los resultados son confiables hasta una velocidad de 40 km/h, ya que luego existieron pocos datos, por lo que se debería profundizar en futuros estudios. A diferencia de investigaciones previas, este procedimiento incluye rangos de velocidades para detectar los baches. Además de la detección de los baches, también se presentan umbrales para calificar la severidad de los mismos. Ambos resultados son la base para utilizarlas en aplicaciones que se puede distribuir en la población con el fin de recolectar datos de las redes viales.

Este estudio tiene una serie de limitaciones. Solo se han probado dos teléfonos inteligentes. Además, solo se han analizado tramos cortos de vías (hasta 2,80 m). También no se conoce si el procedimiento es aplicable en condiciones climáticas adversas o durante la noche. Así mismo, la velocidad máxima detectada estuvo cerca de 60 km/h, aunque su aplicabilidad llega hasta los 40 km/h. A pesar de estas limitaciones, el estudio presentó dos procedimientos para detectar baches y su severidad. Lo expuesto es de baja demanda computacional, lo que facilitaría que se coloquen en aplicaciones de teléfonos inteligentes. De igual modo, el estudio muestra las variables que influyen en la detección y severidad y propone umbrales o valores que se pueden usar en otros estudios. Y, principalmente, que se puedan utilizar para elaborar aplicaciones que recolecten y clasifiquen los baches, cuyo impacto social será considerable. Finalmente, las limitaciones de esta investigación se pueden abordar con mayor profundidad en el futuro.

Reconocimientos

Los autores agradecen a la SENESCYT (Secretaría de Educación Superior, Ciencia, Tecnología e Innovación) y a la Universidad Técnica Particular de Loja por el apoyo brindado en esta investigación.

Referencias

- Agrawal, R., Chhadva, Y., Addagarla, S., & Chaudhari, S. (2021, May 21). Road surface classification and subsequent pothole detection using deep learning. *2021 2nd International Conference for Emerging Technology, INCET 2021*. <https://doi.org/10.1109/INCET51464.2021.9456126>
- Anand, A., Gawande, R., Jadhav, P., Shahapurkar, R., Devi, A., & Kumar, N. (2020). Intelligent Vehicle Speed Controlling and Pothole Detection System. *E3S Web of Conferences*, 170. <https://doi.org/10.1051/E3SCONF/202017002010>
- Arjapure, S., & Kalbande, D. R. (2020). Review on Analysis Techniques for Road Pothole Detection. *Advances in Intelligent Systems and Computing*, 1053, 1189–1197. https://doi.org/10.1007/978-981-15-0751-9_109
- Arulananth, T. S., Baskar, M., Thrishma, K., Srilekha, N., Supraja, S., & Ravalika, C. (2022). Pothole Detection Using Arduino and Ultrasonic Sensors. *Lecture Notes in Networks and Systems*, 292, 435–442. https://doi.org/10.1007/978-981-16-4435-1_42
- Ashwini, K. S., Bhagwat, G., Sharma, T., & Pagala, P. S. (2020, July 1). Trigger-Based Pothole Detection Using Smartphone and OBD-II. *Proceedings of CONECCT 2020 - 6th IEEE International Conference on Electronics, Computing and Communication Technologies*. <https://doi.org/10.1109/CONECCT50063.2020.9198602>
- Aswath, M., Raj, S. J., & Mohanaprasad, K. (2022). Real-Time Pothole Detection with Onboard Sensors and Camera on Vehicles. *Lecture Notes in Electrical Engineering*, 792, 479–488. https://doi.org/10.1007/978-981-16-4625-6_47
- Bangalore Ramaiah, N. K., & Kundu, S. (2021). Stereo Vision Based Pothole Detection System for Improved Ride Quality. *SAE Technical Papers*, 2021. <https://doi.org/10.4271/2021-01-0085>
- Becker, Y. V. F., Siqueira, H. L., Matsubara, E. T., Gonçalves, W. N., & Marcato, J. (2019). Asphalt pothole detection in uav images using convolutional neural networks. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2019-July, 56–58. <https://doi.org/10.1109/IGARSS.2019.8900621>

- Bhavya, P., Sharmila, C., Sai Sadhvi, Y., Prasanna, C. M. L., & Ganesan, V. (2021). Pothole Detection Using Deep Learning. *Lecture Notes in Networks and Systems*, 210 LNNS, 233–243. https://doi.org/10.1007/978-981-16-1773-7_19
- Bridgelall, R., & Tolliver, D. (2020). Accuracy enhancement of anomaly localization with participatory sensing vehicles. *Sensors (Switzerland)*, 20(2). <https://doi.org/10.3390/S20020409>
- Camilleri, N., & Gatt, T. (2020). Detecting road potholes using computer vision techniques. *Proceedings - 2020 IEEE 16th International Conference on Intelligent Computer Communication and Processing, ICCP 2020*, 343–350. <https://doi.org/10.1109/ICCP51029.2020.9266138>
- Chen, H., Yao, M., & Gu, Q. (2020). Pothole detection using location-aware convolutional neural networks. *International Journal of Machine Learning and Cybernetics*, 11(4), 899–911. <https://doi.org/10.1007/S13042-020-01078-7>
- Du, Z., Yuan, J., Xiao, F., & Hettiarachchi, C. (2021). Application of image technology on pavement distress detection: A review. *Measurement: Journal of the International Measurement Confederation*, 184. <https://doi.org/10.1016/J.MEASUREMENT.2021.109900>
- Egaji, O. A., Evans, G., Griffiths, M. G., & Islas, G. (2021). Real-time machine learning-based approach for pothole detection. *Expert Systems with Applications*, 184. <https://doi.org/10.1016/J.ESWA.2021.115562>
- Eriksson, J., Girod, L., Hull, B., Newton, R., Madden, S., & Balakrishnan, H. (2008). The pothole patrol: using a mobile sensor network for road surface monitoring. *6th International Conference on Mobile Systems, Applications, and Services*, 29–39. <https://doi.org/10.1145/1378600.1378605>
- Fan, R., Ozgunalp, U., Hosking, B., Liu, M., & Pitas, I. (2020). Pothole Detection Based on Disparity Transformation and Road Surface Modeling. *IEEE Transactions on Image Processing*, 29, 897–908. <https://doi.org/10.1109/TIP.2019.2933750>
- Fan, R., Ozgunalp, U., Wang, Y., Liu, M., & Pitas, I. (2021). Rethinking Road Surface 3-D Reconstruction and Pothole Detection: From Perspective Transformation to Disparity Map Segmentation. *IEEE Transactions on Cybernetics*. <https://doi.org/10.1109/TCYB.2021.3060461>

- Fan, R., Wang, H., Wang, Y., Liu, M., & Pitas, I. (2021). Graph Attention Layer Evolves Semantic Segmentation for Road Pothole Detection: A Benchmark and Algorithms. *IEEE Transactions on Image Processing*, *30*, 8144–8154. <https://doi.org/10.1109/TIP.2021.3112316>
- Ganesh Babu, R., Chellaswamy, C., Surya Bhupal Rao, M., Saravanan, M., Kanchana, E., & Shalini, J. (2020, July 1). Deep learning based pothole detection and reporting system. *2020 7th International Conference on Smart Structures and Systems, ICSSS 2020*. <https://doi.org/10.1109/ICSSS49621.2020.9202061>
- Gupta, D., Xu, W., Yu, X., & Huang, M. C. (2021). Campus safety and the internet of wearable things: Assessing student safety conditions on campus while riding a smart scooter. *2021 IEEE 17th International Conference on Wearable and Implantable Body Sensor Networks, BSN 2021*. <https://doi.org/10.1109/BSN51625.2021.9507033>
- Gupta, S., Sharma, P., Sharma, D., Gupta, V., & Sambyal, N. (2020). Detection and localization of potholes in thermal images using deep neural networks. *Multimedia Tools and Applications*. <https://doi.org/10.1007/S11042-020-09293-8>
- Han, Y., Kim, S. J., Lee, D. W., Park, J. H., Lee, S. W., & Seo, D. (2020). Development of a pothole detection result management system in road aerial images. *JP Journal of Heat and Mass Transfer*, *2020*(Special Issue 1), 77–81. <https://doi.org/10.17654/HMSI120077>
- Harikrishnan, P. M., & Gopi, V. P. (2017). Vehicle Vibration Signal Processing for Road Surface Monitoring. *IEEE Sensors Journal*, *17*(16), 5192–5197. <https://doi.org/10.1109/JSEN.2017.2719865>
- Hiremath, R., Malshikare, K., Mahajan, M., & Kulkarni, R. V. (2021). A Smart App for Pothole Detection Using Yolo Model. *Lecture Notes in Networks and Systems*, *154*, 155–164. https://doi.org/10.1007/978-981-15-8354-4_16
- Hu, Y., & Furukawa, T. (2020). Degenerate near-planar 3D reconstruction from two overlapped images for road defects detection. *Sensors (Switzerland)*, *20*(6). <https://doi.org/10.3390/S20061640>
- Javed, A., Mahmud, M. S., Alam, M. T., Ohab, M. F. Bin, Ali, K. R., Jobaer, A. Al, & Monir Uddin, M. (2021). Pothole Detection System Using Region-Based Convolutional Neural Network. *2021 IEEE 4th International Conference on Computer and Communication Engineering Technology, CCET 2021*, 6–11. <https://doi.org/10.1109/CCET52649.2021.9544396>

- Kandoi, A., Agarwal, H., Revadekar, A., & Chaudhari, B. N. (2021). Pothole detection using accelerometer and computer vision with automated complaint redressal. *2021 3rd International Conference on Signal Processing and Communication, ICPSC 2021*, 257–264. <https://doi.org/10.1109/ICSPC51351.2021.9451762>
- Kempaiah, B. U., Mampilli, R. J., & Goutham, K. S. (2022). A Deep Learning Approach for Speed Bump and Pothole Detection Using Sensor Data. *Lecture Notes in Electrical Engineering*, 73–85. https://doi.org/10.1007/978-981-16-1338-8_7
- Kharel, S., & Ahmed, K. R. (2022). Potholes Detection Using Deep Learning and Area Estimation Using Image Processing. *Lecture Notes in Networks and Systems*, 296, 373–388. https://doi.org/10.1007/978-3-030-82199-9_24
- Kotha, M., Chadalavada, M., Karuturi, S. H., & Venkataraman, H. (2020, January 11). PotSense - Pothole detection on Indian roads using smartphone sensors. *PervasiveHealth: Pervasive Computing Technologies for Healthcare*. <https://doi.org/10.1145/3377283.3377286>
- Kumar, A., Chakrapani, Kalita, D. J., & Singh, V. P. (2020, February 1). A modern pothole detection technique using deep learning. *2nd International Conference on Data, Engineering and Applications, IDEA 2020*. <https://doi.org/10.1109/IDEA49133.2020.9170705>
- Kyriakou, C., Christodoulou, S. E., & Dimitriou, L. (2019). Smartphone-Based Pothole Detection Utilizing Artificial Neural Networks. *Journal of Infrastructure Systems*, 25(3), 04019019. [https://doi.org/10.1061/\(ASCE\)IS.1943-555X.0000489](https://doi.org/10.1061/(ASCE)IS.1943-555X.0000489)
- Lekshmiopathy, J., Velayudhan, S., & Mathew, S. (2021). Effect of combining algorithms in smartphone based pothole detection. *International Journal of Pavement Research and Technology*, 14(1), 63–72. <https://doi.org/10.1007/S42947-020-0033-0>
- Li, R., & Liu, C. (2021). Road Damage Evaluation via Stereo Camera and Deep Learning Neural Network. *IEEE Aerospace Conference Proceedings, 2021-March*. <https://doi.org/10.1109/AERO50100.2021.9438528>
- Lopes, T. R. L., Dias, L. P. S., Da Costa, C. A., De Nardin, I. F., & Da Rosa Righi, R. (2020). Collaborative humanless model for automatic pothole detection and driver notification. *International Journal of Computational Science and Engineering*, 22(2–3), 280–296. <https://doi.org/10.1504/IJCSE.2020.107350>

- Mamatha, G., Sharan, H. S., Prathik, R., Priya, D. S., & Prajwal, U. (2020). Smart vehicular communication for road status analysis and vehicle trajectory prediction. *Proceedings of the 3rd International Conference on Smart Systems and Inventive Technology, ICSSIT 2020*, 1081–1087. <https://doi.org/10.1109/ICSSIT48917.2020.9214252>
- Muhammad Hanif, H., Lie, Z. S., Astuti, W., & Tan, S. (2020). Pothole detection system design with proximity sensor to provide motorcycle with warning system and increase road safety driving. *IOP Conference Series: Earth and Environmental Science*, 426(1). <https://doi.org/10.1088/1755-1315/426/1/012039>
- Park, J. S., Lee, K. S., & Kim, S. (2019). Assessment for a condition using terrestrial lidar data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 42(3/W8), 311–314. <https://doi.org/10.5194/ISPRS-ARCHIVES-XLII-3-W8-311-2019>
- Park, S. S., Tran, V. T., & Lee, D. E. (2021). Application of various yolo models for computer vision-based real-time pothole detection. *Applied Sciences (Switzerland)*, 11(23). <https://doi.org/10.3390/APP112311229>
- Patra, S., Middya, A. I., & Roy, S. (2021). PotSpot: Participatory sensing based monitoring system for pothole detection using deep learning. *Multimedia Tools and Applications*, 80(16), 25171–25195. <https://doi.org/10.1007/S11042-021-10874-4>
- Pawar, K., Jagtap, S., & Bhoir, S. (2020). Efficient pothole detection using smartphone sensors. *International Conference on Automation, Computing and Communication*, 32. <https://doi.org/10.1051/ITMCONF/20203203013>
- Pratama, I. D., Mahmudah, H., & Sudibyo, R. W. (2021). Design and Implementation of Real-time Pothole Detection using Convolutional Neural Network for IoT Smart Environment. *International Electronics Symposium 2021: Wireless Technologies and Intelligent Systems for Better Human Lives, IES 2021 - Proceedings*, 675–679. <https://doi.org/10.1109/IES53407.2021.9594038>
- Pundir, P., Gupta, S., Patel, R. S., Goswami, R., Singh, D., & Kumar, K. (2021). POCONET: A Pathway to Safety. *Lecture Notes in Networks and Systems*, 175, 299–306. https://doi.org/10.1007/978-3-030-67187-7_31

- Rahman, A., Mustafa, R., & Hossain, M. S. (2022). Real-time Pothole Detection and Localization Using Convolutional Neural Network. In *Lecture Notes on Data Engineering and Communications Technologies* (pp. 579–592). Springer Science and Business Media Deutschland GmbH. https://doi.org/10.1007/978-981-16-6636-0_44
- Ravi, R., Bullock, D., & Habib, A. (2020). Highway and airport runway pavement inspection using mobile lidar. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 43(B1), 349–354. <https://doi.org/10.5194/ISPRS-ARCHIVES-XLIII-B1-2020-349-2020>
- Riedl, K., Huber, S., Bomer, M., Kreibich, J., Nobis, F., & Betz, J. (2020, September 10). Importance of Contextual Information for the Detection of Road Damages. *2020 15th International Conference on Ecological Vehicles and Renewable Energies, EVER 2020*. <https://doi.org/10.1109/EVER48776.2020.9242954>
- Shah, A., Sharma, G., & Bhargava, L. (2021). Smart implementation of computer vision and machine learning for pothole detection. *Proceedings of the Confluence 2021: 11th International Conference on Cloud Computing, Data Science and Engineering*, 65–69. <https://doi.org/10.1109/CONFLUENCE51648.2021.9376886>
- Shahin, M. (2006). *Pavement Management for Airports, Roads, and Parking Lots* (2nd. ed.). Springer.
- Silvester, S., Komandur, D., Kokate, S., Khochare, A., More, U., Musale, V., & Joshi, A. (2019, December 1). Deep Learning Approach to Detect Potholes in Real-Time using Smartphone. *2019 IEEE Pune Section International Conference, PuneCon 2019*. <https://doi.org/10.1109/PUNECON46936.2019.9105737>
- Singh, G., Bansal, D., Sofat, S., & Aggarwal, N. (2017). Smart patrolling: An efficient road surface monitoring using smartphone sensors and crowdsourcing. *Pervasive and Mobile Computing*, 40, 71–88. <https://doi.org/10.1016/J.PMCJ.2017.06.002>
- Singh, K., Hazra, S., Mukherjee, C., Sushanth, G., & Gowda, S. (2020). Iot based real time potholes detection system using image processing techniques. *International Journal of Scientific and Technology Research*, 9(2), 785–789.

- Srivastava, A., Goyal, A., & Ram, S. S. (2020). Radar cross-section of potholes at automotive radar frequencies. *2020 IEEE International Radar Conference, RADAR 2020*, 483–488. <https://doi.org/10.1109/RADAR42522.2020.9114858>
- Thakur, M., Sharma, V., & Wavhal, P. (2020). IoT based pothole detection and warning system. *International Journal of Advanced Science and Technology*, 29(4 Special Issue), 767–770.
- Thiruppathiraj, S., Kumar, U., & Buchke, S. (2020). Automatic pothole classification and segmentation using android smartphone sensors and camera images with machine learning techniques. *IEEE Region 10 Annual International Conference, Proceedings/TENCON, 2020-November*, 1386–1391. <https://doi.org/10.1109/TENCON50793.2020.9293883>
- Tithi, A., Ali, F., & Azrof, S. (2021, July 8). Speed bump & pothole detection with single shot multibox detector algorithm & speed control for autonomous vehicle. *2021 International Conference on Automation, Control and Mechatronics for Industry 4.0, ACMI 2021*. <https://doi.org/10.1109/ACMI53878.2021.9528185>
- Tsai, J. C., Lai, K. T., Dai, T. C., Su, J. J., Siao, C. Y., & Hsu, Y. C. (2020, November 4). Learning Pothole Detection in Virtual Environment. *2020 International Automatic Control Conference, CACS 2020*. <https://doi.org/10.1109/CACS50047.2020.9289740>
- Van Khang, N., & Renault, E. (2019). Cooperative sensing and analysis for a smart pothole detection. *2019 15th International Wireless Communications and Mobile Computing Conference, IWCMC 2019*, 1785–1790. <https://doi.org/10.1109/IWCMC.2019.8766600>
- Vittorio, A., Rosolino, V., Teresa, I., Vittoria, C. M., Vincenzo, P. G., & Francesco, D. M. (2014). Automated Sensing System for Monitoring of Road Surface Quality by Mobile Devices. *Procedia - Social and Behavioral Sciences*, 111, 242–251. <https://doi.org/10.1016/J.SBSPRO.2014.01.057>
- Wang, L. (2021). Research on Road Pothole Detection Method Based on Computer Image Restoration Technology. *Journal of Physics: Conference Series*, 1992(3). <https://doi.org/10.1088/1742-6596/1992/3/032028>

- Yebes, J. J., Montero, D., & Arriola, I. (2021). Learning to Automatically Catch Potholes in Worldwide Road Scene Images. *IEEE Intelligent Transportation Systems Magazine*, 13(3), 192–205. <https://doi.org/10.1109/MITS.2019.2926370>
- Yik, Y. K., Alias, N. E., Yusof, Y., & Isaak, S. (2021). A real-time pothole detection based on deep learning approach. *Journal of Physics: Conference Series*, 1828(1). <https://doi.org/10.1088/1742-6596/1828/1/012001>