# UNIVERSIDAD POLITÉCNICA SALESIANA SEDE QUITO

# CARRERA: INGENIERÍA DE SISTEMAS

Trabajo de titulación previo a la obtención del título de: Ingenieros de Sistemas

# TEMA: "USO DE ALGORITMOS PARA LA IDENTIFICACIÓN DE IMPERFECCIONES EN LA CALZADA: UN MAPEO SISTEMÁTICO"

AUTORES: JONATHAN DAVID AVALOS PÉREZ JULIO DARIO VELASQUEZ COLLAGUAZO

TUTOR: FRANKLIN EDMUNDO HURTADO LARREA

Quito, agosto de 2021

# CESIÓN DE DERECHOS DE AUTOR

Nosotros Jonathan David Avalos Pérez, Julio Dario Velasquez Collaguazo, con documento de identificación N° 1752101459 y N° 1716846504, manifestamos nuestra voluntad y cedemos a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que somos autores del trabajo de titulación intitulado: "USO DE ALGORITMOS PARA LA IDENTIFICACIÓN DE IMPERFECIONES EN LA CALZADA: UN MAPEO SISTEMÁTICO", mismo que ha sido desarrollado para optar el título de: INGENIEROS DE SISTEMAS, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En aplicación a lo determinado en la Ley de Propiedad Intelectual, en nuestra condición de autores nos reservamos los derechos morales de la obra antes citada. En concordancia, suscribimos este documento en el momento que hacemos la entrega del trabajo final en digital a la Biblioteca de la Universidad Politécnica Salesiana.

(ONATHAN)

Jonathan David Avalos Pérez

1752101459

J.

Julio Dario Velasquez Collaguazo

1716846504

Quito, agosto de 2021

DECLARATORIA DE COAUTORÍA DE LA TUTORA

Yo declaro que bajo mi dirección y asesoría fue desarrollado el Artículo académico, con el tema:

"USO DE ALGORITMOS PARA LA IDENTIFICACIÓN DE IMPERFECCIONES EN LA

CALZADA: UN MAPEO SISTEMÁTICO", realizado por Jonathan David Avalos Pérez y Julio

Dario Velasquez Collaguazo, obteniendo un producto que cumple con todos los requisitos

estipulados por la Universidad Politécnica Salesiana para ser considerado como trabajo final de

titulación.

Quito, agosto de 2021

.....

FRANKLIN EDMUNDO HURTADO LARREA

C.I: 1713382016

#### **AGRADECIMIENTOS**

A Dios por bendecir cada paso que doy en mi vida, a mis padres por enseñarme el valor del trabajo y el amor al prójimo, a mi esposa por ser fruto de mi inspiración y finalmente agradezco a mi familia y amigos que fueron testigos y siempre apoyaron mi misión.

Julio Dario Velasquez Collaguazo

Llegar hasta aquí ha sido un camino difícil por algunos factores, lo importante es poder perseverar y no darte por vencido, existen momentos que quieres darte por vencido pero siempre existen personas que están ahí para que no lo hagas, por este motivo quiero dedicar este trabajado de titulación como agradecimiento a quienes han estado para ayudar a cumplir este sueño.

A mi papi Mario quien me enseñó a no darme por vencido por más difícil que sea la situación, que siempre de lo mejor en todo lo que haga por más pequeño que sea, que me apoyo en todo este camino y de quien sigo aprendiendo cada día. A mi mami Patricia quien siempre con su gran amor estuvo en todo momento de mi vida apoyándome en cada paso que daba, la que me dio ese aliento para poder seguir cuando pensaba que no podría seguir estudiando. En verdad les agradezco por ser los mejores padres y estar conmigo en todo momento. Los amo mucho.

A mis hermanos Byron y Roger, a pesar de ser el mayor de los dos aprendo mucho de ustedes, con los que convivo día a día, espero ser un buen ejemplo para ustedes y que sepan que siempre estaré para ustedes cuando me necesiten.

A mi abuelita Luz María por brindarme su apoyo desde pequeño y siempre estar pendiente de todos nosotros, también quiero agradecer al resto de mi familia (tíos, tías, primos y primas) que estuvieron conmigo en todo momento de este camino.

A aquellos ingenieros que fueron mis profesores de los cuales aprendido bastante y me ayudo a desarrollarme como profesional, finalmente a las personas que me dieron la oportunidad de trabajar aún sin tener mucha experiencia ya que fue una gran ayudar para poder culminar mis estudios.

Jonathan David Avalos Pérez

# "USO DE ALGORITMOS PARA LA IDENTIFICACIÓN DE IMPERFECCIONES EN LA CALZADA: UN MAPEO SISTEMÁTICO".

# "USE OF ALGORITHMS FOR THE IDENTIFICATION OF IMPERFECTIONS IN THE ROAD: A SYSTEMATIC MAPPING".

Jonathan David Avalos Pérez<sup>1</sup>, Julio Dario Velasquez Collaguazo<sup>2</sup>, Franklin Edmundo Hurtado Larrea<sup>3</sup>

#### Resumen

La gran mayoría de los accidentes de tránsito son provocados por las imperfecciones en la calzada, por este motivo se ha ido adaptando diferentes algoritmos de inteligencia artificial para su detección.

El propósito de este trabajo se centra en el desarrollo de un análisis de la literatura del periodo comprendido entre las dos últimas décadas que incluye temas relacionados con el uso de algoritmos de inteligencia artificial para la identificación de imperfecciones en la calzada. La metodología empleada en este trabajo se basa en técnicas de Mapeo Sistemático, un proceso que consta de tres etapas: Definiciones de Protocolo, Ejecuciones de Búsqueda y Discusión de Resultados.

Como resultado de este análisis, se obtuvieron 74 artículos relevantes de acuerdo a los criterios de inclusión donde se proponen 41 algoritmos y tres enfoques de identificación de imperfecciones en la calzada, con porcentajes de exactitud desde el 95.45% hasta el 99.8%. Mismos que fueron obtenidos de repositorios como SciencieDirect, IEEE y Scopus.

**Palabras clave:** inteligencia artificial, algoritmo, visión por computadora, basado en vibraciones, reconstrucción en 3D

#### **Abstract**

The vast majority of traffic accidents are caused by imperfections in the road, for this reason different artificial intelligence algorithms have been adapted for their detection.

The purpose of this work is focused on the development of an analysis of the literature of the period between the last two decades that includes topics related to the use of artificial intelligence algorithms for the identification of imperfections in the road. The methodology used in this work is based on Systematic Mapping techniques, a process that consists of three stages: Protocol Definitions, Search Executions and Results Discussion.

As a result of this analysis, 74 relevant articles were obtained according to the inclusion criteria where 41 algorithms and three approaches to identify imperfections in the road are proposed, with percentages of accuracy from 95.45% to 99.8%. The same ones that were obtained from repositories such as SciencieDirect, IEEE and Scopus.

**Keywords:** artificial intelligent, algorithm, computer vision, vibration based, 3D reconstruction

1

<sup>&</sup>lt;sup>1</sup> Estudiante de Ingeniería en Sistemas – Universidad Politécnica Salesiana, Egresada – UPS – sede Quito. Autor para correspondencia: <u>javalosp@est.ups.edu.ec</u>

<sup>&</sup>lt;sup>2</sup> Estudiante de Ingeniería en Sistemas – Universidad Politécnica Salesiana, Egresada – UPS – sede Quito. Autor para correspondencia: <u>jvelasquezc1@est.ups.edu.ec</u>

<sup>&</sup>lt;sup>3</sup> Profesor deIngeniería en Sistemas – UPS – sede Quito. Email: fhurtado@ups.edu.ec

## 1. Introducción

La OMS estima que alrededor de 1.35 millones de personas mueren cada año a causa de accidentes de tránsito. Entre los factores de riesgo existe uno en particular relacionado a una infraestructura vial insegura, específicamente, se habla de imperfecciones en las vías ocasionadas por la mala calidad de los materiales usados para la construcción de carreteras y, además, eventos naturales como la lluvia [1].

El control e identificación de estos desperfectos en las carreteras implica un gran costo de dinero y tiempo por parte de los gobiernos si se lo hace de forma manual [2].

Las carreteras son de gran importancia para la economía de los países ya que son el eje fundamental de la transportación por vía terrestre, por lo cual la construcción de las carreteras se realiza de forma rápida sin tener en cuenta los futuros problemas de mantenimiento debido al mal estado del sistema de drenaje y a los vehículos con sobrecarga [3].

Al momento de viajar, la mayoría de los conductores están enfocados en llegar a su destino en el menor tiempo posible, lo que aumenta la posibilidad de que a lo largo del viaje el vehículo caiga de forma inesperada en baches que se encuentren en la calzada. Conocer estas imperfecciones puede evitar que este tipo de accidentes sucedan [4].

A lo largo de los últimos años, se han realizado muchos estudios con el fin de dar solución a este problema de forma automática, en los cuales se proponen diferentes enfoques y varios algoritmos que ayudan a detectar las imperfecciones en la carretera [5].

Actualmente existen propuestas innovadoras en las que se emplea hardware computacional y algoritmos de Inteligencia

Artificial para reducir en gran medida los costos y el tiempo empleado en el reconocimiento de daños en las vías.

Este trabajo tiene como objetivo realizar un mapeo sistemático de la literatura, con el cual se permitirá realizar un análisis de los artículos que incluyan temas acerca de los algoritmos que permiten el reconocimiento de imperfecciones en la calzada.

De este modo, se puede conocer los enfoques y algoritmos utilizados para el reconocimiento del estado de las carreteras, además, de distintas técnicas de recolección de datos, para así obtener información relevante para posteriores investigaciones, datos que permitan realizar una comparación entre los resultados y aplicación de algoritmos que permitan implementaciones futuras en el Ecuador.

### 2. Marco Teórico

En esta sección se abordan algunos conceptos que son necesarios para poner en contexto al lector.

# 2.1 Enfoques para la detección de imperfecciones en la carretera

Actualmente existen tres enfoques para la detección de baches como se menciona en [6] los cuales son: basado en vibraciones, reconstrucción 3D y la más conocida visión por computadora.

### 2.1.1 Basado en vibraciones

En el enfoque basado en vibraciones se utilizan equipos que contienen dispositivos de medición como acelerómetro y giroscopio para crear un marco basado en vibraciones que permiten la recolección de datos para evaluar el estado del carril. La ventaja en esta técnica es que requiere poca capacidad de

procesamiento, es rentable y transmite los datos en tiempo real. [6].

Un acelerómetro es un dispositivo que nos brinda la capacidad de medir la aceleración en distintos ejes a través de la medición de su propio movimiento en el espacio. Existen 3 tipos de acelerómetro: capacitivos, piezorresistivos y piezoeléctricos, siendo el primero el más pequeño y barato por ello usado principalmente en dispositivos portátiles y móviles.

El giroscopio es un dispositivo el cual permite que al momento de rotar se pueda medir la variación de un ángulo con respecto al tiempo [7].

Dentro de los artículos encontrados se hace uso de sensores a través de dispositivos integrados o externos adaptados.

#### 2.1.2 Reconstrucción 3D

La principal idea detrás de la técnica usada por el escáner laser 3D es emplear pulsos laser reflejados para crear modelos digitales precisos de objetos existentes. Utilizar el equipo de filtrado laser en un vehículo representa todavía un gasto enorme.

La visión estéreo utiliza dos cámaras conjuntas para cubrir la superficie, las imágenes en 2D de las dos cámaras se desglosan cada una para reconocer y caracterizar las imperfecciones. Los procesos de visión estéreo realizan un gran esfuerzo computacional al replicar la superficie a través del marco de coordinación de los centros de inclusión entre dos puntos de vista.

## 2.1.3 Visión por computadora

Para este método se extraen imágenes con y sin imperfecciones para comparar la superficie de un lugar. En el caso que la superficie de la ubicación de la imperfección sea más gruesa y granulada que la superficie circundante se puede ejecutar en Matlab utilizando el kit de herramientas de manejo de imágenes para su

prueba.

Los videos capturados utilizan el cálculo DFS (algoritmo de búsqueda profunda) que sirve para recorrer todos los nodos del grafo o árbol, el cual permite identificar si la calzada tiene algún daño.

## 2.2 Algoritmos

### 2.2.1 Convolutional Neural Network

CNN es una red neuronal profunda que añade más capas al principio de la red que es la encargada de manipular imágenes a través de pixeles, esto quiere decir que es una ampliación de las redes neuronales comunes. Este algoritmo consta de dos capas: capas de convolución y capas de pooling [8].

#### 2.2.2 Método de Otsu

En la visión por computadora y el procesamiento de imágenes, el método de Otsu se utiliza para crear automáticamente el umbral de imagen basado en clústeres, o la reducción de una imagen de nivel de gravilla a una imagen binaria. El algoritmo asume que la imagen contiene dos clases de píxeles siguiendo el histograma bimodal (píxeles de primer plano y píxeles de fondo), luego calcula el umbral óptimo que separa las dos clases para que su dispersión combinada (varianza intraclase) sea mínima. equivalentemente (porque la suma de las distancias cuadradas por pares es constante), por lo que su varianza entre clases es máxima [9].

# 2.2.3 Support Vector Machine

Las máquinas de vectores de soporte (SVM) han ganado prominencia recientemente en el campo del aprendizaje automático y la clasificación de patrones [8]. La clasificación se logra realizando una superficie de separación lineal o no lineal en el espacio de entrada. En la clasificación de

vectores de soporte, la función de separación se puede expresar como una combinación lineal de núcleos asociados con los vectores de soporte [10].

# 2.2.4 Distorsión de tiempo dinámico

El algoritmo de distorsión de tiempo dinámico (DTW) es capaz de encontrar la alineación óptima entre dos series de tiempo. A menudo se utiliza para determinar la similitud de las series de tiempo, la clasificación y para encontrar las regiones correspondientes entre dos series de tiempo. DTW tiene una complejidad cuadrática de tiempo y espacio que limita su uso a pequeños conjuntos de datos de series de tiempo [11].

# 3. Metodología

Este trabajo fue realizado en base a la metodología de Mapeo Sistemático ya que permite que se haga una búsqueda amplia de información sobre uno o varios temas en específico a través de artículos científicos. Como primer paso se identificó una problemática la cual se convirtió en un tema de investigación rigurosa y discusión bien sustentada del estado de la literatura. Una vez identificado el tema se hace un mapeo de la frecuencia de las publicaciones por categorías dentro de un esquema.

De este modo, se determinó la cobertura del campo de investigación. También se pueden combinar diferentes facetas del esquema para responder preguntas de investigación más específicas. Una vez terminada la búsqueda se realiza una discusión de los resultados. El proceso de mapeo sistemático propuesto por Petersen consta de tres etapas, las cuales son: Definiciones de Protocolo, Ejecuciones de Búsqueda y finalmente Discusión de los Resultados [12]. Cada etapa consta de una serie de pasos que pueden observarse en la Figura 1.

Esta metodología consiste en buscar dentro de un área de investigación y así poder realizar un buen estudio. En primera instancia se debe profundizar un dominio de la investigación mediante el uso de métodos que sean rigurosos, sistemáticos y cuyas decisiones estén claramente documentadas.

Una vez identificada la brecha de investigación se mapean las frecuencias de las publicaciones a lo largo del tiempo identificando foros. autores relevantes, metodologías o métodos utilizados. Luego se procede a buscar documentación en base al número de citas (mientras mayor cantidad de citas es mucho mejor), organizaciones, revistas o congresos, por palabras claves o contenidos de acuerdo con los resúmenes de cada uno de los artículos encontrados.

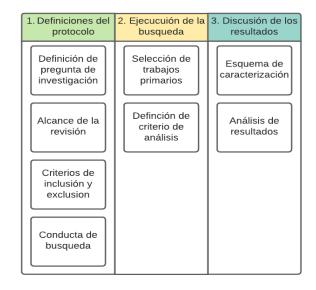


Figura 1. Procesos del mapeo sistemático

# 3.1 Definiciones del protocolo

En la primera parte del mapeo sistemático se comienza definiendo las preguntas, alcance de la revisión, criterio de inclusión y exclusión, y conducta de búsqueda. Todo esto con el fin, de poder seleccionar las investigaciones previas al análisis de resultados.

# 3.1.1 Definiciones de las preguntas de investigación

El mapeo sistemático tiene como primera etapa la definición de las preguntas de investigación, para este estudio se definieron las siguientes preguntas:

Q1: ¿Cuántos y cuáles son los enfoques para la detección automática de imperfecciones en la carretera?

Q2: ¿Cuántas publicaciones se han llevado a cabo durante los últimos 20 años con respecto a la detección de imperfecciones en la carretera?

Q3: ¿Cuáles son los algoritmos más usados en cada categoría?

Q4: ¿Cuáles son las publicaciones que obtuvieron mayor exactitud (accuracy) para la identificación de imperfecciones en la calzada?

Q5: ¿Cuántos artículos obtuvieron resultados cuantitativos y cualitativos?

#### 3.1.2 Alcance de la revisión

Actualmente se pueden encontrar varias bases de datos que contienen publicaciones enfocadas a diversas áreas de investigación, para este artículo se recolectó artículos científicos de los repositorios digitales confiables como: IEEE, Scopus y SciencieDirect, enfocados en la detección de imperfecciones en la vía y que utilicen algoritmos de inteligencia artificial para dicha detección como fuente de información. Acceder a los diferentes tipos de repositorios temáticos e institucionales los cuales poseen tesis o investigaciones que aportan a su comunidad o institución tiene un gran valor de contenido [13]. En la Tabla 1 se muestran los resultados de los repositorios.

Tabla 1. Selección de base de datos

Repositorios	No de documentos
Scopus	193
ScienceDirect	647

IEEE	224
Total	1064

# 3.1.3 Criterios de inclusión y exclusión

Se incluyen aquellos artículos científicos que se relacionen directamente con la detección de imperfecciones en las vías y también que para su objetivo utilicen algoritmos de inteligencia artificial, además que tengan como enfoques la visión por computadora, basado en vibraciones, reconstrucción en 3D o a su vez usen 2 o más de los enfoques mencionados. Para los criterios de exclusión se descartan las publicaciones que no usen algoritmos para la identificación de daños en la carretera.

# 3.1.4 Conducta de búsqueda

En este trabajo se realizó una búsqueda rigurosa de la literatura en los repositorios confiables y reconocidos mencionados anteriormente.

Dado el caso que las bases de datos en su mayoría se encuentran en inglés, para la búsqueda se utilizó las siguientes palabras clave, no obstante, también la búsqueda se realizó en español: "pothole detection", "pothole detection algorithms", "detección de anomalías en las carreteras", "detección de baches en la carretera", "detección de imperfecciones en la carretera", "detección de daños en la carretera", "algoritmos para detectar baches en la carretera", "detection of anomalies on the roads", "detection of potholes in the road", "detection imperfections on the road", "road damage detection", "algorithms for detecting potholes in the road" se utilizaron sinónimos para carretera (vía, calle, avenida, autopista, entre otros).

# 3.2 Ejecución de la búsqueda

En esta sección se lleva a cabo la segunda parte

del mapeo sistemático la cual conlleva la selección de trabajos primarios y definición de criterios de análisis.

# 3.2.1 Selección de trabajos primarios

Para establecer los trabajos primarios se tomaron en cuenta los siguientes filtros de revisión:

#### I. Primer Filtro:

- Revisión que la fecha sea a partir del año 2000 hasta la actualidad.
- Revisión de palabras claves en el título.
- Revisión del resumen (abstract) en el artículo.

# II. Segundo Filtro:

• Se procede a leer el artículo por completo en que aquellos casos en los que pasaron por el primer filtro.

Una vez aplicados los dos filtros como resultado se obtuvieron 74 artículos, el análisis de los trabajos seleccionados se muestran en la Tabla 2.

Tabla 2. Razones de exclusión de artículos

Razón	Cantidad
Artículos duplicados	130
Documentos fuera de rango	55
de año (2000-2021)	
Primer filtro	137
Segundo filtro	102
Total artículos	1064
Total excluidos	990
Total incluidos	74

#### 3.2.2 Definición de criterios de análisis

En esta sección se definen los criterios de búsqueda que se utilizarán para la selección de los artículos más relevantes. Entre los criterios se utilizan:

Enfoque: El documento debe basarse en uno de los enfoques antes mencionados ya sea visión por computador, basado en vibraciones o reconstrucción en 3D.

Año de publicación: Es importante tomar en cuenta el año de publicación del artículo para saber cómo ha ido evolucionando la investigación a lo largo de los años.

Método: El análisis de daños en la calzada tiene que ser a través de las diferentes ramas de la inteligencia artificial como: Aprendizaje de máquina (Machine Learning), Aprendizaje profundo (Deep Learning) o Lógica Difusa (Fuzzy Logic).

Algoritmos e instrumentos utilizados para la recolección de datos: Cada enfoque tiene su forma de recolectar los datos e identificar las imperfecciones en la carretera, identificarlos es un punto de análisis en el cual se va a referenciar el artículo.

#### 3.3 Discusión de los resultados

En esta última sección se realiza el esquema de caracterización y el análisis de resultados.

# 3.3.1 Esquema de caracterización

En este apartado en consideración a algunas preguntas de investigación mencionadas anteriormente se hizo un resumen del mapeo sistemático, en la Figura 4 y 5 se muestra un gráfico de burbujas que indica la cantidad de veces que los algoritmos se utilizaron en los enfoques especificados para el análisis de este estudio, se puede observar en que ocasión los algoritmos fueron usados y con esto se puede especificar los algoritmos más usados en cada enfoque.

#### 3.3.2 Análisis de resultados

Para finalizar el mapeo sistemático, en la sección 3 se presenta el análisis de resultados, la cual responde las preguntas de investigación tomando en cuenta los artículos primarios que fueron seleccionados.

# 4 Resultados y discusión

En esta sección se realizó el análisis de

resultados con las preguntas planteadas anteriormente y una discusión con las respuestas obtenidas.

#### 4.1 Resultados

Los resultados de esta investigación se obtuvieron en base al análisis de cada uno de los artículos descritos en la Tabla 4 y Tabla 5 con el propósito de responder a las preguntas de investigación antes mencionadas:

Q1: ¿Cuántos y cuáles son los enfoques para la detección de imperfecciones en las vías?

En esta investigación se encontró que los enfoques para el reconocimiento de daños en la calzada fueron tres: Visión por computadora, basado en vibraciones y reconstrucción en 3D. También los investigadores, para asegurarse que el modelo tenga una mejor exactitud combinan 2 métodos en este caso: visión por computadora y basado en vibraciones. En la Figura 2 se muestra la cantidad de artículos que se han publicado implementando cada enfoque encontrado.

Dando como resultado que de un total de 74 publicaciones que se muestra en la Tabla 4 los artículos con resultados cuantitativos y en la Tabla 5 las publicaciones con resultados cualitativos, la que posee el título del artículo, método. enfoque, algoritmos, instrumentos/herramientas/recursos. si la aplicación de algoritmo fue simulada o se implementó e indicadores como: precisión, retiro, exactitud y la puntuación F1. Visión por computadora tiene 44 artículos dando como resultado el enfoque más usado para la detección de imperfecciones en la vía es decir se usó un 59.46%, el segundo enfoque más usado es basado en vibraciones teniendo 18 artículos con un 24.32%, reconstrucción 3D se encuentra como tercer puesto con 8 publicaciones con un 10.81% y por último se encuentra la combinación de visión por computadora con basado en vibraciones con un total de 4 artículos con 5.41%.

Q2: ¿Cuántas publicaciones se han llevado a cabo durante los últimos 20 años con respecto a la detección de imperfecciones en la carretera?

En la Figura 3, se muestra que las investigaciones relaciones con la identificación de imperfecciones en la calzada usando algoritmos son a partir del año 2010, en el artículo publicado en ese año se encuentra que el primer enfoque implementado fue visión por computadora.

A partir del año 2015 se muestra un incremento notorio de las investigaciones realizadas, entre los años 2019 y 2020 se publicaron la mayoría de artículos teniendo un total del 50% de publicaciones, esto gracias a que la inteligencia artificial ha ido madurando a lo largo de los años y tomando como consciencia la preocupante situación de los accidentes de tránsito causados por las vías en mal estado.

Q3: ¿Cuáles son los algoritmos más usados en cada categoría?

En las figuras 4 y 5 se realizaron diagramas de burbujas de los algoritmos y enfoques utilizados, se encontraron en total 41 algoritmos los cuales se usaron en los 74 artículos, algunos artículos utilizaban dos o más algoritmos para hacer comparaciones entre ellos y ver cuál era más eficiente.

En el enfoque de visión por computadora entre los algoritmos más usados se encontraron los algoritmos CNN usado en 7 artículos, RCNN en 6 artículos, SVM en 7 artículos y YOLO en 6 artículos.

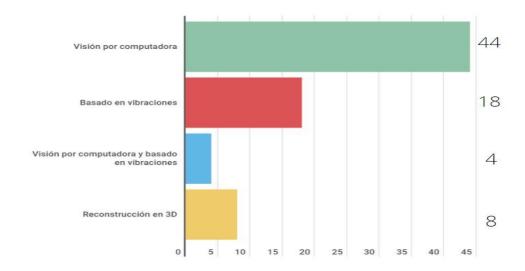


Figura 2. Cantidad de artículos con respecto a enfoques

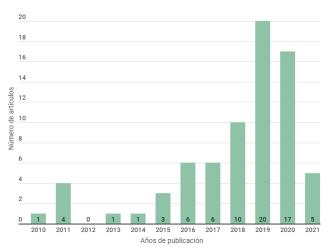


Figura 3. Cantidad de artículos con respecto a enfoques

El enfoque basado en vibraciones tiene como algoritmo mayor usado el SVM en 7 artículos, seguidamente por DTW que fue usado en 4 artículos.

En reconstrucción en 3D el algoritmo más usado fue el método de Otsu usando en 2 a comparación de los otros algoritmos que se usan 1 vez en cada artículo.

Por último, se tiene la combinación de dos enfoques: visión por computadora y basado en vibraciones aquí la mayoría de algoritmos son usados una vez.

El algoritmo SVM es el más usado en todas las publicaciones, ya que tuvo una participación en 7 artículos en visión por computadora, 7 en basado en vibración y 1 en la combinación de ambos, dando un total de 15, el cual cubre un 36.58% de todas las publicaciones. La terminología usada para los algoritmos se puede observar en la Tabla 3.

Q4: ¿Cuáles son las publicaciones que obtuvieron mayor exactitud (accuracy) para la identificación de imperfecciones en la calzada?

Dentro de las publicaciones utilizadas para esta investigación se encontraron métricas obtenidas de una matriz de confusión utilizada en los algoritmos de inteligencia artificial la cual brinda los valores necesarios como los verdaderos positivos (calzada con daño y el modelo lo clasificó como daño), falsos positivos (calzada sin daño y el modelo lo clasificó como daño), verdaderos negativos (calzada sin daño y el modelo lo clasificó como sin daño) y falsos negativos (calzada con daño y el modelo lo clasificó sin daño) para medir el desempeño.

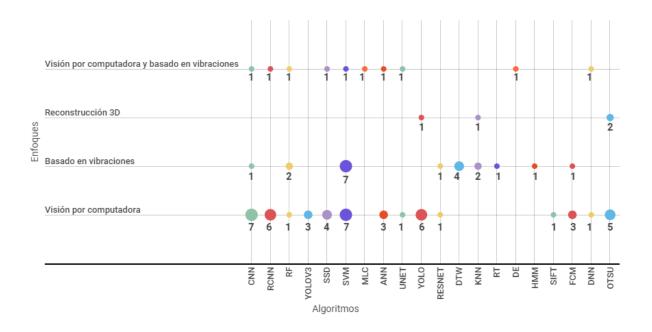


Figura 4. Diagrama de burbujas algoritmos y enfoques utilizados parte 1

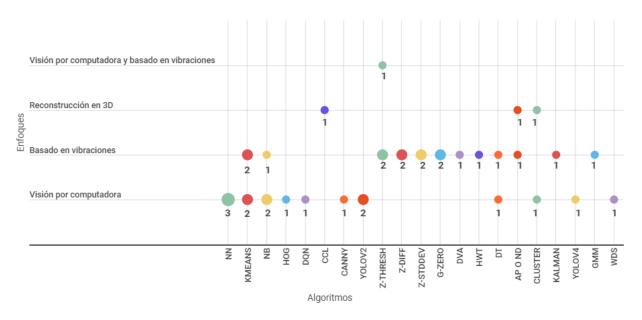


Figura 5. Diagrama de burbujas algoritmos y enfoques utilizados parte 2

Tabla 3. Abreviaciones de algoritmos

Abreviatura  CNN  Convolutional Neural Networks  RCNN  RF  Random Forest  YOLO v3  SSD  Object Detection  SVM  Support Vector Machine  MLC  Multileaf Collimator  ANN  Artificial neural network  UNET  U-Net  YOLO  You Only Look Once  RESNET  residual neural network  dynamic time warping  KNN  k-nearest neighbors  RT  Random Tree  Desviación  Desviación estándar  HMM  Hidden Markov Model  SIFT  Scale-invariant feature  transform  FCM  Fuzzy c-Means  DNN  Deep Neural Network  OTSU  Método de Otsu  NN  Neural Network  K-MEANS  K-means Clustering  NB  Naive Bayes Classifiers  HOG  Histogram of oriented  gradients  DQN  Deep Q Network  CCL  Connected-component  labeling  CANNY  Algoritmo de Canny  YOLO v2  You only look once V2  ZT  Z-THRESH  ZD  Z-DIFF  ZS  Z-STDDEV  GZ  GZ  G-ZERO  DVA  Distance-vector algorithm  HWT  Transformada de Onda de  Haar  Dr  Decision Tree	A heavieture Newhole complete							
Networks RCNN Faster R-CNN RF Random Forest YOLO v3 You only look once V3 SSD Object Detection SVM Support Vector Machine MLC Multileaf Collimator ANN Artificial neural network UNET U-Net YOLO You Only Look Once RESNET residual neural network OTW dynamic time warping KNN k-nearest neighbors RT Random Tree Desviación Desviación estándar HMM Hidden Markov Model SIFT Scale-invariant feature transform FCM Fuzzy c-Means DNN Deep Neural Network OTSU Método de Otsu NN Neural Network K-MEANS K-means Clustering NB Naive Bayes Classifiers HOG Histogram of oriented gradients DQN Deep Q Network CCL Connected-component labeling CANNY Algoritmo de Canny YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS Z-STDDEV GZ GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar	Abreviatura	Nombre completo						
RCNN RF Random Forest YOLO v3 You only look once V3 SSD Object Detection SVM Support Vector Machine MLC Multileaf Collimator ANN Artificial neural network UNET U-Net YOLO You Only Look Once RESNET residual neural network OTW dynamic time warping KNN k-nearest neighbors RT Random Tree Desviación Desviación estándar HMM Hidden Markov Model SIFT Scale-invariant feature transform FCM Fuzzy c-Means DNN Deep Neural Network OTSU Método de Otsu NN Neural Network K-MEANS K-means Clustering NB Naive Bayes Classifiers HOG Histogram of oriented gradients DQN Deep Q Network CCL Connected-component labeling CANNY Algoritmo de Canny YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS Z-STDDEV GZ GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar	CNN							
RF Random Forest YOLO v3 You only look once V3 SSD Object Detection SVM Support Vector Machine MLC Multileaf Collimator ANN Artificial neural network UNET U-Net YOLO You Only Look Once RESNET residual neural network DTW dynamic time warping KNN k-nearest neighbors RT Random Tree Desviación Desviación estándar HMM Hidden Markov Model SIFT Scale-invariant feature transform FCM Fuzzy c-Means DNN Deep Neural Network OTSU Método de Otsu NN Neural Network K-MEANS K-means Clustering NB Naive Bayes Classifiers HOG Histogram of oriented gradients DQN Deep Q Network CCL Connected-component labeling CANNY Algoritmo de Canny YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS Z-STDDEV GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar	D CNN I							
YOLO v3  SSD Object Detection SVM Support Vector Machine MLC Multileaf Collimator ANN Artificial neural network UNET U-Net YOLO You Only Look Once RESNET residual neural network DTW dynamic time warping KNN k-nearest neighbors RT Random Tree Desviación Desviación estándar HMM Hidden Markov Model SIFT Scale-invariant feature transform FCM Fuzzy c-Means DNN Deep Neural Network OTSU Método de Otsu NN Neural Network K-MEANS K-means Clustering NB Naive Bayes Classifiers HOG Histogram of oriented gradients DQN CCL Connected-component labeling CANNY Algoritmo de Canny YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS Z-STDDEV GZ GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar								
SSD Object Detection SVM Support Vector Machine MLC Multileaf Collimator ANN Artificial neural network UNET U-Net YOLO You Only Look Once RESNET residual neural network OTW dynamic time warping KNN k-nearest neighbors RT Random Tree Desviación Desviación estándar HMM Hidden Markov Model SIFT Scale-invariant feature transform FCM Fuzzy c-Means DNN Deep Neural Network OTSU Método de Otsu NN Neural Network K-MEANS K-means Clustering NB Naive Bayes Classifiers HOG Histogram of oriented gradients DQN Deep Q Network CCL Connected-component labeling CANNY Algoritmo de Canny YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS Z-STDDEV GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar								
SVM Support Vector Machine MLC Multileaf Collimator ANN Artificial neural network UNET U-Net U-Net YOLO You Only Look Once RESNET residual neural network DTW dynamic time warping KNN k-nearest neighbors RT Random Tree Desviación Desviación estándar HMM Hidden Markov Model SIFT Scale-invariant feature transform FCM Fuzzy c-Means DNN Deep Neural Network OTSU Método de Otsu NN Neural Network K-MEANS K-means Clustering NB Naive Bayes Classifiers HOG Histogram of oriented agradients DQN Deep Q Network CCL Connected-component labeling CANNY Algoritmo de Canny YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS Z-STDDEV GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar		•						
MLC ANN Artificial neural network UNET U-Net U-Net YOLO You Only Look Once RESNET residual neural network DTW dynamic time warping KNN k-nearest neighbors RT Random Tree Desviación Desviación estándar HMM Hidden Markov Model SIFT Scale-invariant feature transform FCM Fuzzy c-Means DNN Deep Neural Network OTSU Método de Otsu NN Neural Network K-MEANS K-means Clustering NB Naive Bayes Classifiers HOG Histogram of oriented gradients DQN CCL Connected-component labeling CANNY Algoritmo de Canny YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS Z-STDDEV GZ GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar		· ·						
ANN Artificial neural network UNET U-Net U-Net I YOLO You Only Look Once RESNET residual neural network DTW dynamic time warping KNN k-nearest neighbors RT Random Tree Desviación Desviación estándar HMM Hidden Markov Model SIFT Scale-invariant feature transform FCM Fuzzy c-Means DNN Deep Neural Network OTSU Método de Otsu NN Neural Network K-MEANS K-means Clustering NB Naive Bayes Classifiers HOG Histogram of oriented gradients DQN Deep Q Network CCL Connected-component abeling CANNY Algoritmo de Canny YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS Z-STDDEV GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar								
UNET YOLO You Only Look Once RESNET residual neural network DTW dynamic time warping KNN k-nearest neighbors RT Random Tree Desviación Desviación estándar HMM Hidden Markov Model SIFT Scale-invariant feature transform FCM Fuzzy c-Means DNN Deep Neural Network OTSU Método de Otsu NN Neural Network K-MEANS K-means Clustering NB Naive Bayes Classifiers HOG Histogram of oriented gradients DQN Deep Q Network CCL Connected-component labeling CANNY Algoritmo de Canny YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar	MLC	Multileaf Collimator						
YOLO RESNET residual neural network DTW dynamic time warping KNN k-nearest neighbors RT Random Tree Desviación Desviación estándar HMM Hidden Markov Model SIFT Scale-invariant feature transform FCM Fuzzy c-Means DNN Deep Neural Network OTSU Método de Otsu NN Neural Network K-MEANS K-means Clustering NB Naive Bayes Classifiers HOG Histogram of oriented gradients DQN Deep Q Network CCL Connected-component labeling CANNY Algoritmo de Canny YOLO v2 ZT Z-THRESH ZD Z-DIFF ZS Z-STDDEV GZ GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar	ANN	Artificial neural network						
RESNET  DTW  dynamic time warping  KNN  k-nearest neighbors  RT  Random Tree  Desviación  Desviación estándar  HMM  Hidden Markov Model  SIFT  Scale-invariant feature  transform  FCM  Fuzzy c-Means  DNN  Deep Neural Network  OTSU  Método de Otsu  NN  Neural Network  K-MEANS  K-means Clustering  NB  Naive Bayes Classifiers  HOG  Histogram of oriented  gradients  DQN  Deep Q Network  CCL  Connected-component  labeling  CANNY  Algoritmo de Canny  YOLO v2  You only look once V2  ZT  Z-THRESH  ZD  Z-DIFF  ZS  Z-STDDEV  GZ  G-ZERO  DVA  Distance-vector algorithm  HWT  Transformada de Onda de  Haar	UNET	U-Net	1					
DTW dynamic time warping KNN k-nearest neighbors RT Random Tree Desviación Desviación estándar HMM Hidden Markov Model SIFT Scale-invariant feature transform FCM Fuzzy c-Means DNN Deep Neural Network OTSU Método de Otsu NN Neural Network K-MEANS K-means Clustering NB Naive Bayes Classifiers HOG Histogram of oriented gradients DQN Deep Q Network CCL Connected-component labeling CANNY Algoritmo de Canny YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS Z-STDDEV GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar	YOLO	You Only Look Once						
KNN k-nearest neighbors RT Random Tree Desviación Desviación estándar HMM Hidden Markov Model SIFT Scale-invariant feature transform FCM Fuzzy c-Means DNN Deep Neural Network OTSU Método de Otsu NN Neural Network K-MEANS K-means Clustering NB Naive Bayes Classifiers HOG Histogram of oriented agradients DQN Deep Q Network CCL Connected-component labeling CANNY Algoritmo de Canny YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS Z-STDDEV GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de	RESNET	residual neural network						
RT Random Tree  Desviación Desviación estándar  HMM Hidden Markov Model  SIFT Scale-invariant feature  transform  FCM Fuzzy c-Means  DNN Deep Neural Network  OTSU Método de Otsu  NN Neural Network  K-MEANS K-means Clustering  NB Naive Bayes Classifiers  HOG Histogram of oriented agradients  DQN Deep Q Network  CCL Connected-component labeling  CANNY Algoritmo de Canny  YOLO v2 You only look once V2  ZT Z-THRESH  ZD Z-DIFF  ZS Z-STDDEV  GZ G-ZERO  DVA Distance-vector algorithm  HWT Transformada de Onda de Haar	DTW	dynamic time warping						
RT Random Tree  Desviación Desviación estándar  HMM Hidden Markov Model  SIFT Scale-invariant feature transform  FCM Fuzzy c-Means  DNN Deep Neural Network  OTSU Método de Otsu  NN Neural Network  K-MEANS K-means Clustering  NB Naive Bayes Classifiers  HOG Histogram of oriented gradients  DQN Deep Q Network  CCL Connected-component labeling  CANNY Algoritmo de Canny YOLO v2 You only look once V2  ZT Z-THRESH  ZD Z-DIFF  ZS Z-STDDEV  GZ G-ZERO  DVA Distance-vector algorithm  HWT Transformada de Onda de Haar	KNN	k-nearest neighbors	_					
Desviación Desviación estándar HMM Hidden Markov Model SIFT Scale-invariant feature transform FCM Fuzzy c-Means DNN Deep Neural Network OTSU Método de Otsu NN Neural Network K-MEANS K-means Clustering NB Naive Bayes Classifiers HOG Histogram of oriented agradients DQN Deep Q Network CCL Connected-component labeling CANNY Algoritmo de Canny YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS Z-STDDEV GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar	RT	Random Tree						
HMM SIFT Scale-invariant feature transform FCM FUZZY c-Means DNN Deep Neural Network OTSU Método de Otsu NN Neural Network K-MEANS Naive Bayes Classifiers HOG Histogram of oriented gradients DQN Deep Q Network CCL Connected-component labeling CANNY YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar	Desviación	Desviación estándar						
SIFT Scale-invariant feature transform FCM FUZZY c-Means DNN Deep Neural Network OTSU Método de Otsu NN Neural Network K-MEANS K-means Clustering NB Naive Bayes Classifiers HOG Histogram of oriented gradients EQUA CONNECTED CANNY Algoritmo de Canny YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar	HMM	Hidden Markov Model						
FCM Fuzzy c-Means DNN Deep Neural Network OTSU Método de Otsu NN Neural Network K-MEANS K-means Clustering NB Naive Bayes Classifiers HOG Histogram of oriented gradients DQN Deep Q Network CCL Connected-component labeling CANNY Algoritmo de Canny YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS Z-STDDEV GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar	SIFT	Scale-invariant feature						
DNN Deep Neural Network OTSU Método de Otsu NN Neural Network K-MEANS K-means Clustering NB Naive Bayes Classifiers HOG Histogram of oriented gradients DQN Deep Q Network CCL Connected-component labeling CANNY Algoritmo de Canny YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS Z-STDDEV GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar								
DNN Deep Neural Network  OTSU Método de Otsu  NN Neural Network  K-MEANS K-means Clustering  NB Naive Bayes Classifiers  HOG Histogram of oriented gradients  DQN Deep Q Network  CCL Connected-component labeling  CANNY Algoritmo de Canny  YOLO v2 You only look once V2  ZT Z-THRESH  ZD Z-DIFF  ZS Z-STDDEV  GZ G-ZERO  DVA Distance-vector algorithm  HWT Transformada de Onda de Haar		=						
NN Neural Network K-MEANS K-means Clustering NB Naive Bayes Classifiers HOG Histogram of oriented gradients DQN Deep Q Network CCL Connected-component labeling CANNY Algoritmo de Canny YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS Z-STDDEV GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar		=						
NN Neural Network K-MEANS K-means Clustering NB Naive Bayes Classifiers HOG Histogram of oriented gradients DQN Deep Q Network CCL Connected-component labeling CANNY Algoritmo de Canny YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS Z-STDDEV GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar			ŗ					
NB Naive Bayes Classifiers  HOG Histogram of oriented gradients  DQN Deep Q Network  CCL Connected-component labeling  CANNY Algoritmo de Canny  YOLO v2 You only look once V2  ZT Z-THRESH  ZD Z-DIFF  ZS Z-STDDEV  GZ G-ZERO  DVA Distance-vector algorithm  HWT Transformada de Onda de Haar								
HOG Histogram of oriented gradients  DQN Deep Q Network  CCL Connected-component labeling  CANNY Algoritmo de Canny  YOLO v2 You only look once V2  ZT Z-THRESH  ZD Z-DIFF  ZS Z-STDDEV  GZ G-ZERO  DVA Distance-vector algorithm  HWT Transformada de Onda de Haar	K-MEANS	K-means Clustering	e					
gradients  DQN  Deep Q Network  CCL  Connected-component labeling  CANNY  Algoritmo de Canny  YOLO v2  You only look once V2  ZT  Z-THRESH  ZD  Z-DIFF  ZS  Z-STDDEV  GZ  G-ZERO  DVA  Distance-vector algorithm  HWT  Transformada de Onda de Haar	NB	Naive Bayes Classifiers						
DQN  CCL  Connected-component labeling  CANNY  Algoritmo de Canny  YOLO v2  You only look once V2  ZT  Z-THRESH  ZD  Z-DIFF  ZS  Z-STDDEV  GZ  G-ZERO  DVA  Distance-vector algorithm  HWT  Transformada de Onda de Haar	HOG	9	8					
CCL Connected-component labeling Not canny Algoritmo de Canny YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS Z-STDDEV GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar		•						
labeling CANNY Algoritmo de Canny YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS Z-STDDEV GZ GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar	•	<u> </u>	9					
CANNY YOLO v2 You only look once V2 ZT Z-THRESH ZD Z-DIFF ZS Z-STDDEV GZ GZ G-ZERO DVA Distance-vector algorithm HWT Transformada de Onda de Haar	CCL		e					
YOLO v2  ZT  Z-THRESH  ZD  Z-DIFF  ZS  Z-STDDEV  GZ  G-ZERO  DVA  Distance-vector algorithm  HWT  Transformada de Onda de Haar	CANININ	e						
ZT Z-THRESH CONTROLL		-						
ZD Z-DIFF  ZS Z-STDDEV  GZ G-ZERO  DVA Distance-vector algorithm  HWT Transformada de Onda de Haar								
ZS Z-STDDEV t GZ G-ZERO  DVA Distance-vector algorithm HWT Transformada de Onda de Haar								
GZ G-ZERO  DVA Distance-vector algorithm  HWT Transformada de Onda de Haar								
DVA Distance-vector algorithm HWT Transformada de Onda de Haar								
HWT Transformada de Onda de Haar			٠					
HWT Transformada de Onda de Haar		<u>-</u>	1					
Haar	HWT							
Decision free	DT							
	וע	Decision Tree	-					

Para definir estas métricas se utilizaron los siguientes parámetros:

Nombre completo

definido

Kalman filter

Algoritmo propio o no

Clustering Algorithm

You only look once V4

Gaussian Mixture Models

WDS Clustering Algorithm

Abreviatura

AP o ND

CLUSTER KALMAN

YOLO v4

GMM WDS

La precisión (precision) que muestra la capacidad del clasificador de no etiquetar como positiva una muestra que es negativa, el retiro (recall) que muestra la capacidad de encontrar todas las muestras positivas, la exactitud (acurracy) nos brinda el número de predicciones correctas que el modelo propuesto obtiene sobre todos los tipos de predicciones realizadas y la puntuación F1 (F1-Score) se obtuvo el promedio ponderado de la precisión y el retiro.

Existen cuatro algoritmos con mayor porcentaje de exactitud (accurracy), para obtenerlos se hizo una selección con un rango entre el 95% al 100%.

El articulo [14] mediante el uso del algoritmo CNN alcanzó un porcentaje de exactitud de 99.80%, precisión 100%, retiro 99.60 %, puntuación F1 99.6%, esto se obtuvo entrenando la red con 13.244 imágenes y fue validado con 3.250 imágenes, el diseño de la red neuronal consta de cuatro capas convolucionales, cuatro capas agrupadas y una capa completamente conectada. Se utilizan como hiperparámetros un tamaño de filtro de tres, un filtro de agrupación de tamaño de dos, con un paso de uno y relleno de ceros.

La publicación [15] con el método de Otsu logró una exactitud de 99.64%, precisión de 77.09%, retiro de 98.15% y puntaje F1 de 86.35, donde el algoritmo consta de tres componentes principales: a) trasformación de

disparidad, b) extracción de áreas de carreteras sin daños y c) modelo de mapas de disparidad y detección de baches.

En el artículo [16] con el algoritmo SVM alcanzó una exactitud de 95.7%, precisión de 97% y retiro de 94.1%. El 18.5% de las imágenes contienen regiones falsas positivas, mientras que las imágenes del 9.2% contienen las regiones falsas negativas.

En la publicación [17] con el algoritmo FastDTW logró una exactitud de 95.45%. La exactitud de clasificación se calcula con un promedio de 20 ejecuciones, el cual actualiza sus datos cada 14 días.

Q5: ¿Cuántos artículos obtuvieron resultados cuantitativos y cualitativos?

En esta investigación se encontró que el total de artículos que dieron como resultado un rendimiento al usar el algoritmo para reconocimiento de imperfecciones en la calzada fueron 47, es decir, al finalizar el experimento se obtuvo una precisión, exactitud, retiro o puntaje F1. En la Tabla 4 se muestran los artículos que tienen resultados cuantitativos.

Los artículos cualitativos se pueden observar en la Tabla 5, estos artículos en su gran mayoría como es el caso de [9] los resultados se muestran en una escala, dando como resultado que el algoritmo puede lograr una alta tasa de rendimiento. En [41] el autor menciona que el sistema propuesto proporciona resultados fiables y precisos a partir de las muestras analizadas. En la Tabla 5, los autores de los diferentes artículos manifiestan los resultados de forma cualitativa.

#### 4.2 Discusión

En la Figura 4 en el eje X se muestran los algoritmos y en el eje Y se muestran los enfoques usados en cada artículo para la detección de imperfecciones en la calzada, se puede observar que el algoritmo SVM es el más utilizado en visión por computadora y basado en vibraciones aplicándolo en 7 artículos de cada enfoque, al ser uno de los más usados se ha ido mejorando a lo largo de los años así teniendo un

95.7% de exactitud en la detección de daños en la vía.

En la Figura 5 se encuentra la cantidad de artículos con la relación que existe entre algoritmos y enfoques usado para identificación en imperfecciones en la calzada, en [18] y en [19] se utilizan exactamente los mismos algoritmos que son: ZT, ZD, ZS y GZ.

Reconstrucción en 3D es un enfoque que tiene un gran costo para su implementación, a pesar de que el primer artículo publicado en el año 2011 con ese enfoque se obtuvieron resultados por debajo en comparación con los otros dos enfoques, siendo el método de Otsu el único que se utiliza en dos publicaciones.

En la Tabla 4 y Tabla 5 se pueden observar los instrumentos, recursos herramientas que aportan para la identificación de imperfecciones en la calzada, algunos de ellos son equipos físicos que están integrados en dispositivos como pueden ser la cámara, acelerómetro, giroscopio y GPS, comúnmente en el celular el cual se usa en 24 publicaciones o automóvil que se usa en 6 publicaciones, también pueden ser dispositivos externos integrados en una placa como RaspberryPi usado en 5 publicaciones y Arduino usado en 3 artículos o también se utiliza programas de simulación como el simulador de conducción CarSim en [20] o FTire en [21].

Los estudios realizados muestran que las propuestas de detección de daños en las vías en 65 casos fueron implementados los algoritmos que se usó, es decir, el algoritmo fue puesto en marcha y probado en situaciones reales, en 7 casos se usó software para simular las carreteras y así probar la exactitud de como el algoritmo reacciona una vez implementado y en 2 no se encuentra definido. En algunos casos como en [22] las aplicaciones creadas estas desplegadas en Play Store para Android y en App Store para iOS, la aplicación tiene como nombre RoadApp, usa el algoritmo Decision Tree logrando una exactitud del 92%

para el reconocimiento de imperfecciones en la calzada y para la recolección de datos usa los sensores del teléfono inteligente (acelerómetro y giroscopio) y GPS, esta aplicación usa el método basado en vibraciones.

**Tabla 4.** Descripción de mapeo sistemático de los 47 artículos cuantitativos relevantes

Ref	ME	EN	Algoritmos	I/H/R	SI	Año	Rendimiento
[15]	ML	3D	El método de Otsu	Cámara estéreo ZED	IM	2011	P=98.04,A=99.64,R=98.15,FS=98
[77]	ND	BV	GMM	Acelerómetros GPS	IM	2013	A=90
[4]	ML	BV	RF, K means	Smartphone	IM	2015	P=90
[28]	ML	VC	SVM, ANN	Smartphone, GPS	IM	2016	P=75.35,A=72.8,R=76.95,FS=76.14
[35]	ML	BV	Desviación estándar	Smartphone, Cámara web, Laser IMU	IM	2016	P=95.43
		VC					
[46]	DL	VC	NB, HOG	Conjunto de imágenes	IM	2016	P=86.5,A=90,R=94.1
[50]	ND	VC	El método de Otsu	Smartphone	IM	2016	P=90,R=100
[29]	ML	BV	DTW	Smartphone	IM	2017	
[39]	LD	VC	FCM	ND	ND	2017	
[69]	ND	3D	ND	Sensores	ND	2017	
[14]	DL	VC	CNN	Computadora	IM		P=100,A=99.8,R=99.6,FS=99.6
[34]	ML	VC	SVM, ANN, RF	UAV	IM	2018	P=98.78
[36]	ML	BV	KNN, DTW, SVM,	Smartphone	IM	2018	P=97
			HMM, ResNet				
[37]	ML	BV	SVM	Smartphone	IM	2018	P=99.6
[16]	ML	VC	SIFT, SVM	Cámara	IM	2018	P=97,A=95.7,R=94.1
[57]	ND	VC	Algoritmo de Canny	Raspberry-Pi	IM	2018	P=93.72
[66]	ML	VC	SVM, NB, DT	Smartphone	IM	2018	P=85,A=95,R=78
[67]	ND	BV	ND	Sensores ultrasónicos, Arduino	IM	2018	A=94
[74]	DL	VC	CNN	Cámara	IM	2018	P=92,R=93,FS=93
[17]	ML	BV	SVM, FastDTW	Sensores, GPS de teléfono	IM	2018	A=95.45
[25]	ML	BV	SVM, DT, NN	Smartphone	IM	2019	P=74.79,A=90.15,R=65.68
[27]	DP	VC	YOLO, ResNet, CNN	Cámara	IM	2019	P=88.9
[31]	DL	VC	UNet	Cámara de un Smartphone	IM	2019	P=97
[33]	ML	BV	RF, RT, SVM	Smartphone	IM	2019	P=94
[38]	DL	VC	CNN	Cámara térmica	IM	2019	P=97.08
[40]	DL	BV	SSD, DNN	Smartphone	IM	2019	P=96.7
		VC					
[47]	DL	VC	Red neuronal	Sensor ultrasónico Acelerómetro Cámara estéreo, GPS, Raspberry Pi	IM	2019	P=90
[53]	DL	VC	YOLO V3	Cámara Pavement View DataSet	IM	2019	P=94,R=82
[56]	ML	VC		UAV	IM	2019	
[59]	DL	VC	RCNN, YOLOv2	Conjunto de datos CCSAD, Urban Streets y CCSAD	IM	2019	P=88,R=84
[64]	DL	VC	RCNN	Cámara de teléfono	IM	2019	A=97,R=100
[22]	ND	BV	DT	Acelerómetro y giroscopio del teléfono	IM	2019	P=100,A=92,R=83,FS=91
[75]	ML	VC	Redes neuronales	Imágenes del camino indio	IM	2019	A=95
[3]	DL	VC	RCNN	Cámara, Computadora	IM	2020	P= 90
[5]	DL	VC	YOLO V3, SSD, SVM, R-CNN	Cámara, Computadora	IM	2020	P=82
[23]	DL	BV VC	SVM, MLC, RF, ANN, GMM, RCNN, UNet	Computadora, Cámara, Smartphone	IM	2020	P=56.1,A=71.58,R=49.09,FS=52.36
[24]	DL	VC	RCNN	Cámara de Smartphone, Computadora	IM	2020	P=85
[30]	DL	BV	CNN, Kirchhoff, KNN	Sensores en el automóvil	IM	2020	P=99.2
[43]	DL	VC	YOLO	Smartphone	IM	2020	P=76
[-13]	שע	, ,	1020	Singrepriorie	1171	2020	1-10

Ref	ME	EN	Algoritmos	I/H/R	SI	Año	Rendimiento
[61]	ML	VC	ANN, SVM	Google y recopilación manual	IM	2020	P=84.6,A=90.3,R=100,FS=91
[65]	DL	VC	YOLO, SSD	Smartphone Raspberry Pi	IM	2020	P=77,R=63
[18]	DL	VC	YOLO, R-CNN	Smartphone	IM	2020	P=87,R=89
[73]	DL	VC	YOLOv4	ND	IM	2020	P=58,A=60,R=37
[79]	ML	VC	DNN	ND	IM	2021	A=93.7
[80]	DL	VC	YOLOv3	Webcam, GPS, Laptop	SM	2021	P=90,R=45
[82]	ML	VC	YOLO	Smartphone	SM	2021	A=83.6
[83]	DL	VC	YOLOv2	Smartphone	SM	2021	P=67

Tabla 5. Descripción de mapeo sistemático de los 27 artículos cualitativos relevantes

Ref	ME	EN	Algoritmos	I/H/R	SI	Año
[49]	ML	VC	SVM	ND	IM	2010
[41]	ML	VC	Otsu, Red neuronal	Imágenes laser	IM	2011
[51]	ML	3D	El método de Otsu	Dos sensores CCD	IM	2011
[19]	ND	BV	ZT, ZD, ZS, GZ	Acelerómetro, Smartphone	IM	2011
[55]	ML	3D	CCL	Cámara estereoscópica	IM	2014
[20]	ML	BV	SVM	Acelerómetros en el vehículo, CarSim	IM	2015
[21]	ND	BV	Naive Bayes	FTire	SM	2015
[42]	ML	VC	Otsu, K-Means, FCM	ND	IM	2016
[68]	ND	3D	KNN	Cámaras RGB, Acelerómetros GPS, IMU	IM	2016
[26]	ML	VC	Clúster	2d lidar sensor Cámara	IM	2017
[32]	ML	BV	SVM	Sensores en el automóvil	IM	2017
[76]	ND	VC	Método de Otsu	Imágenes de Google	IM	2017
[2]	DL	VC	CNN	Computadora, Raspberry, Cámara	IM	2019
[52]	ML	BV	DTW	Sensores de teléfonos	IM	2019
[54]	ML	VC	El método de Otsu	ND	IM	2019
[58]	ND	VC	Canny, K-Means, FCM	Internet y de Bangladesh	IM	2019
[60]	ND	BV	ZT, ZD, ZS, GZ, DVA	Acelerómetro, GPS	IM	2019
[63]	ND	BV	HWT	Smartphone	IM	2019
[72]	DL	VC	CNN	Cámara web Logitech C525	IM	2019
[44]	DL	3D	YOLO	Imágenes reales y simuladas	SM	2020
[45]	DL	VC	YOLO	Google Images	IM	2020
[48]	DL	VC	DQN, SSD, YOLOv3	Simulador de conducción, CARLA	SM	2020
[62]	ND	BV,VC	ZT, RCNN	Smartphone Módulo OBD-II	IM	2020
[70]	ML	3D	Clustering Algorithm	Láser de línea 3D	IM	2020
[71]	ND	BV	K-means	GPS, Módulo MPU-92/65	IM	2020
[78]	ND	VC	SSD	Cámara Raspberry pi	IM	2020
[81]	DL	VC	Werner D Striedt	Raspberry Pi2, Arduino UNO	SM	2021

Glosario

EN = Enfoque VC = Vision por computadora BV = Basado en vibraciones 3D = Reconstrucción en 3D ME = Método DL = Deep Learning ML = Machine Learning LD = Lógica difusa SI = Simulación/Implementación IM = Implementación SM = Simulación ND = No definido I/H/R = INSTRUMENTOS HERRAMIENTAS RECURSOS P = PRECISION A = ACURRANCY R = RECALL FS = F1 SCORE UAV = VEHICULO AEREO NO TRIPULADO

# 5 Conclusiones

Se ha realizado un estudio en base a la metodología de mapeo sistemático acerca del uso de algoritmos para la identificación de imperfecciones en la calzada. Se obtuvieron 74 publicaciones distribuidas en tres enfoques (visión por computadora, basado en vibraciones y reconstrucción en 3D), siendo la visión por computadora el enfoque más utilizado con un total de 44 publicaciones.

Las publicaciones que hacen uso del enfoque basada en vibraciones obtuvieron resultados similares al método de visión por computadora. Los datos recogidos mediante sensores (giroscopio y acelerómetro) tienen una tendencia a brindar falsos positivos ya que es mucho más complicado para el algoritmo detectar un tipo de falla de la calzada de otra. Para esto algunas publicaciones hacen uso de una metodología híbrida el cual consiste en combinar los datos recogidos por vibraciones y confirmar por medio de la visión por computadora. La unión de estos dos enfoques da como resultado un mayor porcentaje de exactitud, pero a la vez incrementando la inversión en tiempo y recursos. Por consiguiente se puede decir que hasta el momento la mejor forma de implementar este tipo de proyectos es visión por computadora.

En la búsqueda realizada observamos que en trabajos anteriores se llevó a acabó la etapa de simulación y experimentación. Algunas publicaciones llegaron a mostrar sus propuestas a los respectivos gobernantes de su ciudad y puestas en marcha para así reducir los accidentes de tránsito ocurridos por los daños en las vías.

Este estudio puede ser usado como una forma rápida de entender el estado actual de proyectos afines a la identificación o detección de imperfecciones en la calzada. Puede ser usado como un punto de partida para trabajos relacionados o nuevas implementaciones ya que las publicaciones usadas en este artículo son parte de las dos últimas décadas.

### 6 Referencias

- [1] O. m. d. l. salud. "Accidentes de tránsito."

  <a href="https://www.who.int/es/news-room/fact-sheets/detail/road-traffic-injuries">https://www.who.int/es/news-room/fact-sheets/detail/road-traffic-injuries</a> (accessed.
- [2] A. Rasyid *et al.*, "Pothole Visual Detection using Machine Learning Method integrated with Internet of Thing Video Streaming Platform," in 2019 International Electronics Symposium (IES), 27-28 Sept. 2019 2019, pp. 672-675, doi: 10.1109/ELECSYM.2019.8901626.
- [3] A. Kumar, Chakrapani, D. J. Kalita, and V. P. Singh, "A Modern Pothole Detection technique using Deep Learning," in 2nd**International** Conference on Data, Engineering and Applications (IDEA), 28-29 Feb. 2020 2020. pp. 1-5. 10.1109/IDEA49133.2020.9170705.
- [4] M. Ghadge, D. Pandey, and D. Kalbande, "Machine learning approach for predicting bumps on road," in 2015 International Conference on Applied and Theoretical Computing and Communication Technology (iCATccT), 29-31 Oct. 2015 2015, pp. 481-485, doi: 10.1109/ICATCCT.2015.7456932.
- [5] P. Ping, X. Yang, and Z. Gao, "A Deep Learning Approach for Street Pothole Detection," in 2020 IEEE Sixth International Conference on Big Data Computing Service and Applications (BigDataService), 3-6 Aug. 2020 2020, pp. 198-204, doi: 10.1109/BigDataService49289.2020.0 0039.
- [6] P. D. Riya, K. R. Nakulraj, and A. A. Anusha, "Pothole Detection Methods," in 2018 3rd International Conference on Inventive Computation Technologies (ICICT), 15-16 Nov.

- 2018 2018, pp. 120-123, doi: 10.1109/ICICT43934.2018.9034440.
- [7] D. F. Pozo Espín, "Diseño y construcción de una plataforma didáctica para medir ángulos de inclinación usando sensores inerciales como acelerómetro y giroscopio," *BIBDIGITAL*,
- [8] L. O. Chua, "CNN: A Vision of Complexity," *International Journal of Bifurcation and Chaos*, vol. 07, no. 10, pp. 2219-2425, 1997/10/01 1997, doi: 10.1142/S0218127497001618.
- [9] S. Scholar. "Otsu's method." https://www.semanticscholar.org/topic/ Otsu%27s-method/576615 (accessed.
- [10] S. V. M. Vishwanathan and M. N. Murty, "SSVM: a simple SVM algorithm," in *Proceedings of the 2002 International Joint Conference on Neural Networks. IJCNN'02 (Cat. No.02CH37290)*, 12-17 May 2002 2002, vol. 3, pp. 2393-2398 vol.3, doi: 10.1109/IJCNN.2002.1007516.
- [11] S. Salvador and P. Chan, "FastDTW: Toward Accurate Dynamic Time Warping in Linear Time and Space," ed: Semantic Scholar, 2004.
- [12] D. Carrizo and J. Rojas, "Metodologías, técnicas y herramientas en ingeniería de requisitos: un mapeo sistemático," *Ingeniare. Revista chilena de ingeniería*, vol. 26, pp. 473-485, 2018.
- [13] M. A. Echeverría, "Acceso Abierto y software libre," (in Español), *Revista e-Ciencias de la Información*, vol. 4, no. 2, pp. 1-12, 2014.
- [14] V. Pereira, S. Tamura, S. Hayamizu, and H. Fukai, "A Deep Learning-Based Approach for Road Pothole Detection in Timor Leste." in 2018 *IEEE* International Conference on Service **Operations** and Logistics, and Informatics (SOLI), 31 July-2 Aug. 2018 2018, 279-284, doi: pp. 10.1109/SOLI.2018.8476795.
- [15] R. Fan, U. Ozgunalp, B. Hosking, M.

- Liu, and I. Pitas, "Pothole Detection Based on Disparity Transformation and Road Surface Modeling," *IEEE Transactions on Image Processing*, vol. 29, pp. 897-908, 2020, doi: 10.1109/TIP.2019.2933750.
- [16] M. H. Yousaf, K. Azhar, F. Murtaza, and F. Hussain, "Visual analysis of asphalt pavement for detection and localization of potholes," *Advanced Engineering Informatics*, vol. 38, pp. 527-537, 2018/10/01/ 2018, doi: <a href="https://doi.org/10.1016/j.aei.2018.09.0">https://doi.org/10.1016/j.aei.2018.09.0</a> 02.
- [17] B. Bose, J. Dutta, S. Ghosh, P. Pramanick, and S. Roy, "D&RSense: Detection of Driving Patterns and Road Anomalies," in 2018 3rd International Conference On Internet of Things: Smart Innovation and Usages (IoT-SIU), 23-24 Feb. 2018 2018, pp. 1-7, doi: 10.1109/IoT-SIU.2018.8519861.
- [18] R. Rastogi, U. Kumar, A. Kashyap, S. Jindal, and S. Pahwa, "A Comparative Evaluation of the Deep Learning Algorithms for Pothole Detection," in 2020 IEEE 17th India Council International Conference (INDICON), 10-13 Dec. 2020 2020, pp. 1-6, doi: 10.1109/INDICON49873.2020.93425 58.
- [19] A. Mednis, G. Strazdins, R. Zviedris, G. Kanonirs, and L. Selavo, "Real time pothole detection using Android smartphones with accelerometers," in 2011 International Conference on Distributed Computing in Sensor Systems and Workshops (DCOSS), 27-29 June 2011 2011, pp. 1-6, doi: 10.1109/DCOSS.2011.5982206.
- [20] A. Fox, B. V. K. V. Kumar, J. Chen, and F. Bai, "Crowdsourcing undersampled vehicular sensor data for pothole detection," in 2015 12th Annual IEEE International Conference on Sensing,

- Communication, and Networking (SECON), 22-25 June 2015 2015, pp. 515-523, doi: 10.1109/SAHCN.2015.7338353.
- [21] Z. Li, I. Kolmanovsky, E. Atkins, J. Lu, and D. Filev, "Road anomaly estimation: Model based pothole detection," in 2015 American Control Conference (ACC), 1-3 July 2015 2015, pp. 1315-1320, doi: 10.1109/ACC.2015.7170915.
- [22] M. Y. Alam *et al.*, "Crowdsourcing from the True crowd: Device, vehicle, road-surface and driving independent road profiling from smartphone sensors," *Pervasive and Mobile Computing*, vol. 61, p. 101103, 2020/01/01/ 2020, doi: <a href="https://doi.org/10.1016/j.pmcj.2019.101">https://doi.org/10.1016/j.pmcj.2019.101</a>
- [23] S. Thiruppathiraj, U. Kumar, and S. Buchke, "Automatic pothole classification and segmentation using android smartphone sensors and camera images with machine learning techniques," in 2020 IEEE REGION 10 CONFERENCE (TENCON), 16-19 Nov. 2020 2020, pp. 1386-1391, 10.1109/TENCON50793.2020.9293883
- [24] Z. Hasan, S. N. Shampa, T. R. Shahidi, and S. Siddique, "Pothole and Speed Breaker Detection Using Smartphone Cameras and Convolutional Neural Networks," in 2020 IEEE Region 10 Symposium (TENSYMP), 5-7 June 2020 2020, pp. 279-282, doi: 10.1109/TENSYMP50017.2020.923058 7.
- [25] A. Basavaraju, J. Du, F. Zhou, and J. Ji, "A Machine Learning Approach to Road Surface Anomaly Assessment Using Smartphone Sensors," *IEEE Sensors Journal*, vol. 20, no. 5, pp. 2635-2647, 2020, doi: 10.1109/JSEN.2019.2952857.
- [26] B. Kang and S. Choi, "Pothole detection system using 2D LiDAR and camera," in 2017 Ninth International Conference on Ubiquitous and Future Networks

- (*ICUFN*), 4-7 July 2017 2017, pp. 744-746, doi: 10.1109/ICUFN.2017.7993890.
- [27] S. Shah and C. Deshmukh, "Pothole and Bump detection using Convolution Neural Networks," in 2019 IEEE Transportation Electrification Conference (ITEC-India), 17-19 Dec. 2019 2019, pp. 1-4, doi: 10.1109/ITEC-India48457.2019.ITECINDIA2019-186
- [28] A. Tedeschi and F. Benedetto, "A real-time automatic pavement crack and pothole recognition system for mobile Android-based devices," *Advanced Engineering Informatics*, vol. 32, pp. 11-25, 2017/04/01/ 2017, doi: <a href="https://doi.org/10.1016/j.aei.2016.12.0">https://doi.org/10.1016/j.aei.2016.12.0</a> 04.
- [29] G. Singh, D. Bansal, S. Sofat, and N. Aggarwal, "Smart patrolling: efficient road surface monitoring using smartphone sensors crowdsourcing," Pervasive and Mobile Computing, vol. 40, pp. 71-88, 2017/09/01/ 2017, doi: https://doi.org/10.1016/j.pmcj.2017.06 .002.
- [30] R. G. B, C. C, S. B. R. M, M. S, E. K, and J. S, "Deep Learning Based Pothole Detection and Reporting System," in 2020 7th International Conference on Smart Structures and Systems (ICSSS), 23-24 July 2020 2020, pp. 1-6, doi: 10.1109/ICSSS49621.2020.9202061.
- [31] V. Pereira, S. Tamura, S. Hayamizu, and H. Fukai, "Semantic Segmentation of Paved Road and Pothole Image Using U-Net Architecture," in 2019 International Conference of Advanced Informatics: Concepts, Theory and Applications (ICAICTA), 20-21 Sept. 2019 2019, pp. 1-4, doi: 10.1109/ICAICTA.2019.8904105.
- [32] A. Fox, B. V. K. V. Kumar, J. Chen,

- and F. Bai, "Multi-Lane Pothole Crowdsourced Detection from Undersampled Vehicle Sensor Data," *IEEE* **Transactions** on Mobile Computing, vol. 16, no. 12, pp. 3417-3430. 2017. doi: 10.1109/TMC.2017.2690995.
- [33] M. R. Dey, U. Satapathy, P. Bhanse, B. K. Mohanta, and D. Jena, "MagTrack: Detecting Road Surface Condition using Smartphone Sensors and Machine Learning," in *TENCON 2019 2019 IEEE Region 10 Conference (TENCON)*, 17-20 Oct. 2019 2019, pp. 2485-2489, doi: 10.1109/TENCON.2019.8929717.
- [34] Y. Pan, X. Zhang, G. Cervone, and L. Yang, "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*, vol. 11, no. 10, pp. 3701-3712, 2018, doi: 10.1109/JSTARS.2018.2865528.
- [35] Y. Hsu, J. Perng, and Z. Wu, "Design and implementation of an intelligent road detection system with multisensor integration," in 2016 International Conference on Machine Learning and Cybernetics (ICMLC), 10-13 July 2016 2016, vol. 1, pp. 219-225, doi: 10.1109/ICMLC.2016.7860904.
- [36] F. S. Cabral, M. Pinto, F. A. L. N. Mouzinho, H. Fukai, and S. Tamura, "An Automatic Survey System for Paved and Unpaved Road Classification and Road Anomaly Detection using Smartphone Sensor," in 2018 IEEE International Conference on Service Operations and Logistics, and Informatics (SOLI), 31 July-2 Aug. 2018 2018, pp. 65-70, doi: 10.1109/SOLI.2018.8476788.
- [37] G. Singal, A. Goswami, S. Gupta, and T. Choudhary, "Pitfree: Pot-holes detection on Indian Roads using Mobile Sensors," in 2018 IEEE 8th International Advance Computing Conference (IACC), 14-15

- Dec. 2018 2018, pp. 185-190, doi: 10.1109/IADCC.2018.8692120.
- Aparna, Y. Bhatia, R. Rai, V. Gupta, [38] and Aggarwal, A. "Convolutional neural networks based potholes detection using thermal imaging," Journal of King University Computer and Information Sciences, 2019/02/05/ 2019, doi: https://doi.org/10.1016/j.jksuci.2019.0 2.004.
- [39] Y. O. Ouma and M. Hahn, "Pothole detection on asphalt pavements from 2D-colour pothole images using fuzzy c-means clustering and morphological reconstruction," *Automation in Construction*, vol. 83, pp. 196-211, 2017/11/01/ 2017, doi: <a href="https://doi.org/10.1016/j.autcon.2017.08.017">https://doi.org/10.1016/j.autcon.2017</a>. 08.017.
- [40] S. Silvister *et al.*, "Deep Learning Approach to Detect Potholes in Real-Time using Smartphone," in *2019 IEEE Pune Section International Conference (PuneCon)*, 18-20 Dec. 2019 2019, pp. 1-4, doi: 10.1109/PuneCon46936.2019.910573 7.
- [41] X. Yu and E. Salari, "Pavement pothole detection and severity measurement using laser imaging," in *INTERNATIONAL* 2011 *IEEE* **CONFERENCE** ONELECTRO/INFORMATION TECHNOLOGY, 15-17 May 2011 2011, 1-5, doi: pp. 10.1109/EIT.2011.5978573.
- [42] K. Vigneshwar and B. H. Kumar, "Detection and counting of pothole using image processing techniques," in 2016 IEEE International Conference on Computational Intelligence and Computing Research (ICCIC), 15-17 Dec. 2016 2016, pp. 1-4, doi: 10.1109/ICCIC.2016.7919622.
- [43] J. D, V. S. D, S. A. A, R. K, and L.

- Parameswaran, "Deep Learning based Detection of potholes in Indian roads using YOLO," in 2020 International Conference on Inventive Computation Technologies (ICICT), 26-28 Feb. 2020 2020, pp. 381-385, doi: 10.1109/ICICT48043.2020.9112424.
- [44] J. C. Tsai, K. T. Lai, T. C. Dai, J. J. Su, C. Y. Siao, and Y. C. Hsu, "Learning Pothole Detection in Virtual Environment," in 2020 International Automatic Control Conference (CACS), 4-7 Nov. 2020 2020, pp. 1-5, doi: 10.1109/CACS50047.2020.9289740.
- [45] P. A. Chitale, K. Y. Kekre, H. R. Shenai, R. Karani, and J. P. Gala, "Pothole Detection and Dimension Estimation System using Deep Learning (YOLO) and Image Processing," in 2020 35th International Conference on Image and Vision Computing New Zealand (IVCNZ), 25-27 Nov. 2020 2020, pp. 1-6, doi: 10.1109/IVCNZ51579.2020.9290547.
- [46] K. Azhar, F. Murtaza, M. H. Yousaf, and H. A. Habib, "Computer vision based detection and localization of potholes in asphalt pavement images," in 2016 IEEE Canadian Conference on Electrical and Computer Engineering (CCECE), 15-18 May 2016 2016, pp. 1-5, doi: 10.1109/CCECE.2016.7726722.
- [47] D. Desai, A. Soni, D. Panchal, and S. Gajjar, "Design, Development and Testing of Automatic Pothole Detection and Alert System," in 2019 IEEE 16th India Council International Conference (INDICON), 13-15 Dec. 2019 2019, pp. 1-4, doi: 10.1109/INDICON47234.2019.9030271
- [48] C. W. Kuan, W. H. Chen, and Y. C. Lin, "Pothole Detection and Avoidance via Deep Learning on Edge Devices," in 2020 International Automatic Control Conference (CACS), 4-7 Nov. 2020 2020, pp. 1-6, doi:

- 10.1109/CACS50047.2020.9289701.
- [49] J. Lin and Y. Liu, "Potholes Detection Based on SVM in the Pavement Distress Image," in 2010 *International* Symposium onDistributed **Computing** and Applications to Business, Engineering and Science, 10-12 Aug. 2010 2010, 544-547, doi: 10.1109/DCABES.2010.115.
- [50] I. Schiopu, J. P. Saarinen, L. Kettunen, and I. Tabus, "Pothole detection and tracking in car video sequence," in 2016 39th International Conference on Telecommunications and Signal Processing (TSP), 27-29 June 2016 2016, pp. 701-706, doi: 10.1109/TSP.2016.7760975.
- [51] Y. He, J. Wang, Q. Hanxing, W. Zhang, and X. Jianfang, "A research of pavement potholes detection based on three-dimensional projection transformation," in 2011 4th International Congress on Image and Signal Processing, 15-17 Oct. 2011 2011, vol. 4, pp. 1805-1808, doi: 10.1109/CISP.2011.6100646.
- [52] X. Zhao, X. Wu, Y. Sun, H. Huang, Y. Du, and Z. Cao, "CPDM: An Efficient Crowdsensing-Based Pothole Detection and Measurement System Design," in 2019 IEEE 31st International Conference on Tools with Artificial Intelligence (ICTAI), 4-6 Nov. 2019 2019, pp. 547-554, doi: 10.1109/ICTAI.2019.00082.
- [53] E. N. Ukhwah, E. M. Yuniarno, and Y. K. Suprapto, "Asphalt Pavement Pothole Detection using Deep learning method based on YOLO Neural Network," in 2019 International Seminar on Intelligent Technology and Its Applications (ISITIA), 28-29 Aug. 2019 2019, pp. 35-40, doi: 10.1109/ISITIA.2019.8937176.
- [54] T. D. Chung and M. K. A. A. Khan, "Watershed-based Real-time Image

- Processing for Multi-Potholes Detection on Asphalt Road," in 2019 IEEE 9th International Conference on System Engineering and Technology (ICSET), 7-7 Oct. 2019 2019, pp. 268-272, doi: 10.1109/ICSEngT.2019.8906371.
- [55] Z. Zhang, X. Ai, C. K. Chan, and N. Dahnoun, "An efficient algorithm for pothole detection using stereo vision," in 2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 4-9 May 2014 2014, pp. 564-568, doi: 10.1109/ICASSP.2014.6853659.
- [56] Y. V. F. Becker, H. L. Siqueira, E. T. Matsubara, W. N. Gonçalves, and J. M. Marcato, "Asphalt Pothole Detection in UAV Images Using Convolutional Neural Networks," in *IGARSS 2019 2019 IEEE International Geoscience and Remote Sensing Symposium*, 28 July-2 Aug. 2019 2019, pp. 56-58, doi: 10.1109/IGARSS.2019.8900621.
- [57] M. M. Garcillanosa, J. M. L. Pacheco, R. E. Reyes, and J. J. P. S. Juan, "Smart Detection and Reporting of Potholes via Image-Processing using Raspberry-Pi Microcontroller," in 2018 10th International Conference on Knowledge and Smart Technology (KST), 31 Jan.-3 Feb. 2018 2018, pp. 191-195, doi: 10.1109/KST.2018.8426203.
- [58] A. Ahmed, S. Islam, and A. Chakrabarty, "Identification and Comparative Analysis of Potholes using Image Processing Techniques," in 2019 IEEE Region 10 Symposium (TENSYMP), 7-9 June 2019 2019, pp. 497-502, doi: 10.1109/TENSYMP46218.2019.897138 5.
- [59] A. Dhiman and R. Klette, "Pothole Detection Using Computer Vision and Learning," *IEEE Transactions on Intelligent Transportation Systems*, vol. 21, no. 8, pp. 3536-3550, 2020, doi: 10.1109/TITS.2019.2931297.
- [60] N. V. Khang and R. É, "Cooperative

- Sensing and Analysis for a Smart Pothole Detection," in 2019 15th International Wireless Communications & Mobile Computing Conference (IWCMC), 24-28 June 2019 2019, pp. 1785-1790, doi: 10.1109/IWCMC.2019.8766600.
- [61] L. d. A. Schmidt, M. Pasin, and S. M. Peres, "Feasibility Study for an Automatic Architecture for Pothole Detection in Asphalt Images: a Tradeoff between Performance and Quality," in 2020 IEEE 16th International Conference on Intelligent Computer Communication and Processing (ICCP), 3-5 Sept. 2020 2020, pp. 307-314, doi: 10.1109/ICCP51029.2020.9266229.
- [62] K. S. Ashwini, G. Bhagwat, T. Sharma, and P. S. Pagala, "Trigger-Based Pothole Detection Using Smartphone and OBD-II," in 2020 *IEEE* Conference *International* onElectronics, Computing and Communication **Technologies** (CONECCT), 2-4 July 2020 2020, pp. 10.1109/CONECCT50063.2020.9198 602.
- [63] R. S. Rodrigues, M. Pasin, A. Kozakevicius, and V. Monego, "Pothole Detection in Asphalt: An Automated Approach to Threshold Computation Based on the Haar Wavelet Transform," in 2019 IEEE 43rd Annual Computer Software and **Applications** Conference (COMPSAC), 15-19 Jul 2019 2019. 306-315. vol. 1. pp. 10.1109/COMPSAC.2019.00053.
- [64] K. E. An, S. W. Lee, S. Ryu, and D. Seo, "Detecting a pothole using deep convolutional neural network models for an adaptive shock observing in a vehicle driving," in 2018 IEEE International Conference on Consumer Electronics (ICCE), 12-14

- Jan. 2018 2018, pp. 1-2, doi: 10.1109/ICCE.2018.8326142.
- [65] N. Camilleri and T. Gatt, "Detecting road potholes using computer *IEEE* techniques," 2020 in 16th International Conference on Intelligent Communication Computer Processing (ICCP), 3-5 Sept. 2020 2020, 343-350, doi: pp. 10.1109/ICCP51029.2020.9266138.
- P. Phisanbut. P. [66] Khumsap, N. Watanapongse, and P. Piamsa-nga, "Novel Feature Extractions for Reflection, Alligator Cracks and Potholes Road Surface Classification," in 2018 22nd International Computer Science and Engineering Conference (ICSEC), 21-24 Nov. 2018 2018, pp. 1-4, doi: 10.1109/ICSEC.2018.8712645.
- [67] M. M. Forrest, Z. Chen, S. Hassan, I. O. Raymond, and K. Alinani, "Cost Effective Surface Disruption Detection System for Paved and Unpaved Roads," *IEEE Access*, vol. 6, pp. 48634-48644, 2018, doi: 10.1109/ACCESS.2018.2867207.
- [68] Y. L. Chen *et al.*, "Inexpensive Multimodal Sensor Fusion System for Autonomous Data Acquisition of Road Surface Conditions," *IEEE Sensors Journal*, vol. 16, no. 21, pp. 7731-7743, 2016, doi: 10.1109/JSEN.2016.2602871.
- [69] H. Qiu et al., "Towards Robust Vehicular Context Sensing," *IEEE Transactions on Vehicular Technology*, vol. 67, no. 3, pp. 1909-1922, 2018, doi: 10.1109/TVT.2017.2771623.
- [70] X. She, Z. Hongwei, Z. Wang, and J. Yan, "Feasibility study of asphalt pavement pothole properties measurement using 3D line laser technology," *International Journal of Transportation Science and Technology*, vol. 10, no. 1, pp. 83-92, 2021/03/01/2021, doi: <a href="https://doi.org/10.1016/j.ijtst.2020.07.00">https://doi.org/10.1016/j.ijtst.2020.07.00</a>

- [71] L. Sitanayah, A. Angdresey, and E. sensor-based Kristalino, "A application for road conditions detection: poster abstract," presented at the Proceedings of the 18th Conference on Embedded Networked Sensor Systems, Virtual Event, Japan, 2020. [Online]. Available: https://bibliotecas.ups.edu.ec:2582/10. 1145/3384419.3430437.
- A. D. Wiratmoko et al., "Design of [72] Potholes Detection Road's Feasibility Data Information Using Convolutional Neural 2019 Network(CNN)," in International *Symposium* on Electronics and Smart Devices (ISESD), 8-9 Oct. 2019 2019, pp. 1-5, doi: 10.1109/ISESD.2019.8909461.
- [73] M. Omar and P. Kumar, "Detection of Roads Potholes using YOLOv4," in 2020 International Conference on Information Science and Communications Technologies (ICISCT), 4-6 Nov. 2020 2020, pp. 1-6, doi: 10.1109/ICISCT50599.2020.9351373.
- [74] S. Anand, S. Gupta, V. Darbari, and S. Kohli, "Crack-pot: Autonomous Road Crack and Pothole Detection," in 2018 Digital Image Computing: Techniques and Applications (DICTA), 10-13 Dec. 2018 2018, pp. 1-6, doi: 10.1109/DICTA.2018.8615819.
- [75] H. T. M and A. Danti, "Detection and Classification of Potholes in Indian Roads Using Wavelet Based Energy Modules," in 2019 International Conference on Data Science and Communication (IconDSC), 1-2 March 2019 2019, pp. 1-7, doi: 10.1109/IconDSC.2019.8816878.
- [76] E. Buza, A. Akagic, S. Omanovic, and H. Hasic, "Unsupervised method for detection of high severity distresses on asphalt pavements," in 2017 IEEE 14th International Scientific Conference on

- Informatics, 14-16 Nov. 2017 2017, pp. 45-50, doi: 10.1109/INFORMATICS.2017.832722 0.
- K. Chen, M. Lu, G. Tan, and J. Wu, [77] "CRSM: Crowdsourcing Based Road Surface Monitoring," in 2013 IEEE 10th *International* Conference High Performance **Computing** and **Communications** & 2013 *IEEE* International Conference on Embedded and Ubiquitous Computing, 13-15 Nov. 2013, pp. 2151-2158, 10.1109/HPCC.and.EUC.2013.308.
- [78] K. A. Govada, H. P. Jonnalagadda, P. Kapavarapu, S. Alavala, and K. S. Vani, "Road Deformation Detection," in 2020 7th International Conference on Smart Structures and Systems (ICSSS), 23-24 July 2020 2020, pp. 1-5, doi: 10.1109/ICSSS49621.2020.9202131.
- [79] A. Shah, G. Sharma, and L. Bhargava, "Smart Implementation of Computer Vision and Machine Learningfor Pothole Detection," in 2021 11th International Conference on Cloud Computing, Data Science & Engineering (Confluence), 28-29 Jan. 2021 2021, pp. 65-69, doi: 10.1109/Confluence51648.2021.937688 6.
- [80] Y. K. Yik, N. E. Alias, Y. Yusof, and S. Isaak, "A Real-time Pothole Detection

- Based on Deep Learning Approach," *Journal of Physics: Conference Series*, vol. 1828, no. 1, p. 012001, 2021/02/01 2021, doi: 10.1088/1742-6596/1828/1/012001.
- [81] R. Sulistyowati, A. Suryowinoto, H. A. Sujono, and I. Iswahyudi, "Monitoring of road damage detection systems using image processing methods and Google Map," *IOP Conference Series: Materials Science and Engineering*, vol. 1010, p. 012017, 2021/01/16 2021, doi: 10.1088/1757-899x/1010/1/012017.
- [82] R. Hiremath, K. Malshikare, M. Mahajan, and R. V. Kulkarni, "A Smart App for Pothole Detection Using Yolo Model," in *ICT Analysis and Applications*, Singapore, S. Fong, N. Dey, and A. Joshi, Eds., 2021//2021: Springer Singapore, pp. 155-164.
- [83] P. Pundir, S. Gupta, R. S. Patel, R. Goswami, D. Singh, and K. Kumar, "POCONET: A Pathway to Safety," in *Conference Proceedings of ICDLAIR2019*, Cham, M. Tripathi and S. Upadhyaya, Eds., 2021// 2021: Springer International Publishing, pp. 299-306.