

BumpBusters: Detección de Baches con Aprendizaje Automático en la Ciudad Autónoma de Buenos Aires

Nicolás Bertillod¹, Patricio Cassanelli¹, Macarena Gorgal¹ y Pablo Inchausti¹

¹ Universidad Argentina de la Empresa (UADE)
Instituto de Tecnología (INTEC). Buenos Aires, Argentina
`{nbertillod, pcassanelli, mgorgal, pinchausti}@uade.edu.ar`

Resumen. La presencia de baches en la vía pública compromete la seguridad vial y genera perjuicios tanto al ciudadano afectado como a la sociedad. En este contexto, se propone para las áreas urbanas de la Ciudad Autónoma de Buenos Aires (CABA) un sistema para la detección de baches en tiempo real utilizando los sensores de acelerómetro y geolocalización de los dispositivos móviles. Para esto, se desarrolla un modelo de aprendizaje automático que combina la técnica de *Random Forest* para la detección de baches y *K-Means* para clasificarlos según su gravedad. El prototipo se prueba utilizando un vehículo a escala 1:18, y las visualizaciones se presentan geolocalizadas en un dashboard con *Google Maps*. Se utiliza Grafana para el monitoreo con alertas para los usuarios y los organismos de control. Como línea de extensión, se propone la integración con plataformas como *Waze* y *Cabify* para facilitar su adopción masiva.

Palabras clave: Seguridad Vial, Aprendizaje Automático, Clasificación.

BumpBusters: Pothole Detection with Machine Learning in the Autonomous City of Buenos Aires

Abstract. The presence of potholes in public roads compromises road safety, affects quality of life, and causes economic harm both to the affected citizens and to society. In this context, a system is proposed for urban areas of the Autonomous City of Buenos Aires (CABA) to detect potholes in real time using the accelerometer and geolocation sensors of mobile devices. For this purpose, a machine learning model is developed that combines the *Random Forest* technique for pothole detection and *K-Means* to classify them according to their severity. The prototype is tested using a 1:18 scale vehicle, and the visualizations are geolocated and displayed on a dashboard using *Google Maps*. As a future extension, integration with platforms such as *Waze* and *Cabify* is proposed to facilitate adoption and large-scale distribution.

Keywords: Road Safety, Machine Learning, Classification.

1 Introducción

El deterioro de las calzadas en los centros urbanos afecta la calidad de vida de sus habitantes. La presencia de baches compromete la seguridad vial, aumentando el riesgo de accidentes, especialmente para los usuarios más vulnerables como peatones y conductores de motos y bicicletas. También, un pavimento defectuoso genera un impacto negativo tanto para la economía como el medio ambiente: se incrementa el consumo de combustible, se acelera el desgaste de los vehículos y eleva las emisiones de CO₂ afectando al entorno. (Peña González & Díaz Pineda, 2020)

1.1 Antecedentes

Respecto a trabajos relacionados, la ciudad de Boston ofrecía a sus ciudadanos la aplicación *Street Bump* para registrar baches de forma colaborativa. Utilizaba el GPS y acelerómetro, y funcionó hasta el año 2014 en que se discontinuó (City of Boston, 2019), sin embargo, la fuente de datos de *Street Bump* pudo ser reutilizada, y en un trabajo posterior un dataset de 814 baches se reutilizó para clasificaciones de baches en función de la gravedad y el trabajo de reparación requerido. (Brisimi et al., 2016)

Otro trabajo sobre la detección de baches utilizando los acelerómetros y el GPS instalados en el dispositivo móvil se realizó en la ciudad italiana de Cosenza. Aquí se definió un algoritmo basado en el “*impulso vertical de aceleración*” (*DVA*, en inglés) para detectar “*anomalías*” en el movimiento de vehículo, que se puedan asumir como provocadas por irregularidades en la superficie del camino. (Vittorio et al., 2014)

Respecto a la Ciudad de CABA, se ofrecen canales de contacto para solicitar el arreglo de baches, tanto al número telefónico 147 de la ciudad como por Internet (Buenos Aires Ciudad, 2016).

2 Materiales y Métodos

El presente trabajo desarrolla un sistema denominado *BumpBusters* para la detección de baches en la Ciudad Autónoma de Buenos Aires (CABA) con un prototipo a escala 1:18 (ver Fig 1) con los siguientes componentes integrados:

- **Auto a control remoto:** Gadnic Truck12 - Dimensiones: 22.50 x 36 x 19.50 cm
- **Dispositivo móvil:** Samsung SM-A127M - Android 13
- **Mesa Extensible:** Dimensiones del tablero: 200 x 75 cm.

Según la Fig. 1, en el front se utiliza *React Native* para acceder a los servicios nativos del celular, como el acelerómetro y el GPS. En el backend se utiliza *Node.js* y *Express* con una API para la integración de datos. Para el entrenamiento de los modelos de aprendizaje automático, se utilizan librerías especializada de *Python* como *Pandas*, *NumPy*, *Scikit-learn* y *Matplotlib*. También se describe la de persistencia.

InfluxDB: base de datos especializada en series temporales, que se utiliza para registrar los datos recolectados por los sensores del dispositivo móvil. Cada registro

incluye de lectura del acelerómetro (ejes x, y, z), la ubicación geográfica del GPS (latitud y longitud), y una marca temporal de cuándo se tomaron las mediciones.

Grafana: es una herramienta de código abierto utilizada para el monitoreo de datos en tiempo real y en el proyecto se integra con *InfluxDB*. Presenta el tablero con el mapa de las ubicaciones geográficas obtenidas.

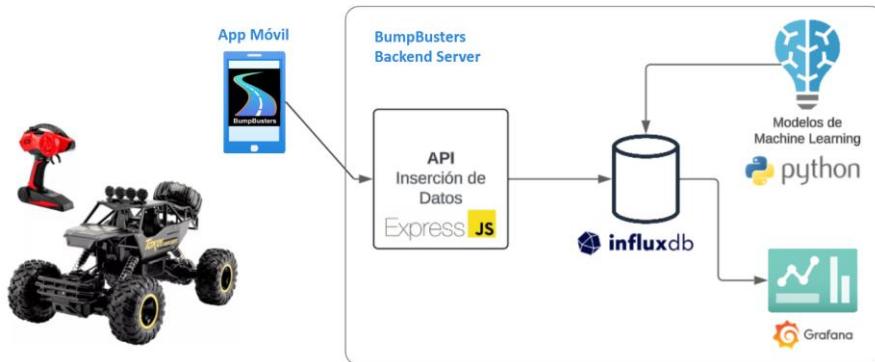


Fig. 1. Presentación del prototipo *BumpBusters* y su arquitectura de alto nivel

2.1 Método de detección y clasificación de baches

Para simular los baches y su gravedad, se utiliza la escala: 0 cm (sin bache - superficie lisa), 1-4 cm (bache pequeño), 5-7 cm (bache moderado) y 8-9 cm (bache grave).

A partir del análisis de lecturas del eje Z del acelerómetro, se identifica la presencia de perturbaciones con el siguiente rango de valores: cuando la superficie es lisa y carente de baches los valores del eje Z varían entre 0 y 20 m/s², en cambio, cuando se presentan baches, las lecturas del eje Z varían entre -20 y 80 m/s².

Estas lecturas son utilizadas como entrada del primer modelo de *Random Forest*, tanto para el entrenamiento supervisado, como la identificación del bache durante la utilización del modelo. Luego, estas salidas que corresponden a baches detectados son utilizadas por un segundo modelo de clasificación con *K-Means* que determina la gravedad de bache de acuerdo con el comportamiento estadístico de los valores del eje Z y el tiempo asociado en su secuencia de entrada.

2.2 Pruebas realizadas

Para validar la precisión del modelo, se realizaron pruebas sobre las dos clases que el modelo distingue, con los siguientes resultados:

- **Clase 0: Negativo - No bache:** precisión del 98% y un *recall* del 95%, resultando en un *F1-score* del 97%. Esto implica un modelo efectivo en identificar y clasificar correctamente esta clase.
- **Clase 1: Positivo - Bache:** tuvo una precisión del 90% y un *recall* del 95%, con un *F1-score* del 92%. Con una precisión menor respecto a la clase 0, el alto *recall* indica que se identifican la mayoría de los casos positivos reales.

La matriz de confusión mostró 4 falsos positivos y 2 falsos negativos. El bajo número de falsos negativos sugiere un modelo confiable en detectar casos positivos. La validación cruzada alcanzó un 90% de precisión con una desviación estándar del 6%, lo que indica que el modelo es estable y consistente. En general, el modelo obtuvo una precisión del 95.2%, lo que indica una alta efectividad en la clasificación.

En la Fig. 2 presenta los resultados en el dashboard con los baches y su severidad:

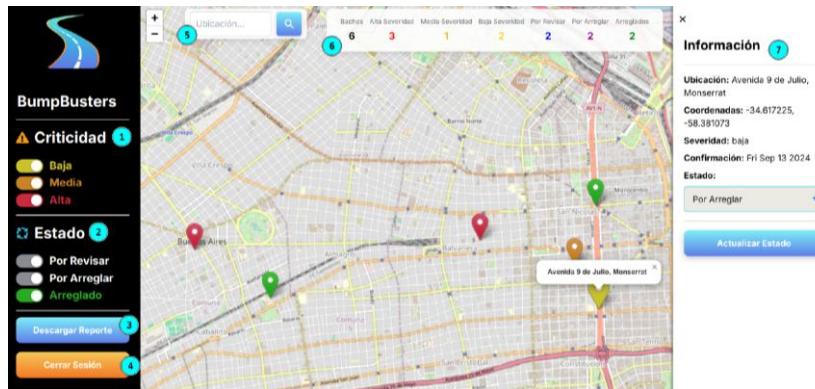


Fig. 2. Presentación de *BumpBusters* con los baches detectados y su severidad

3 Conclusiones

La propuesta de *BumpBusters* se posiciona como una solución innovadora y accesible, que aprovecha los sensores integrados en dispositivos móviles y técnicas de *machine learning* para automatizar la detección de baches en tiempo real.

Los resultados obtenidos en las pruebas iniciales y los comentarios positivos de los usuarios potenciales evidencian la pertinencia de esta solución para las ciudades modernas donde la movilidad y la seguridad vial son cada vez más relevantes.

Referencias

- Brisimi, T. S., Cassandras, C. G., Osgood, C., Paschalidis, I. CH., & Zhang, Y. (2016). Sensing and Classifying Roadway Obstacles in Smart Cities: The Street Bump System. *IEEE Access*, 4, 1301-1312. <https://doi.org/10.1109/ACCESS.2016.2529562>
- Buenos Aires Ciudad. (2016). *Cómo solicitar el arreglo de baches*. Gobierno CABA <https://buenosaires.gob.ar/noticias/como-solicitar-el-arreglo-de-baches>
- City of Boston. (2019). *Street Bump*. <https://www.boston.gov/transportation/street-bump>
- Peña González, E. de la, & Díaz Pineda, J. (2020). Análisis de la relación entre el estado de conservación del pavimento, el consumo de combustible y las emisiones de los vehículos. *Carreteras: Revista técnica de la Asociación Española de la Carretera*. ISSN 0212-6389, 231, 17-27.
- 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>