



UNIVERSIDAD
NACIONAL
DE COLOMBIA

Diseño de un modelo de aprendizaje de máquina para reconocimiento y clasificación de daños en pavimento para vías de Sogamoso.

Diego Camilo Mayorga Ballesteros
Ingeniero Civil

Universidad Nacional de Colombia
Facultad de Minas
Área Curricular de Ingeniería de Sistemas e Informática
Maestría en Ingeniería – Analítica
Medellín – 2023

Diseño de un modelo de aprendizaje de máquina para reconocimiento y clasificación de daños en pavimento para vías de Sogamoso.

Diego Camilo Mayorga Ballesteros

Tesis o trabajo de investigación presentada(o) como requisito parcial para optar al título de:

Magister en Ingeniería - Analítica

Director, Fernán Alonso Villa Garzón

Línea de Investigación:
Analítica

Universidad Nacional de Colombia
Facultad de Minas
Área Curricular de Ingeniería de Sistemas e Informática
Maestría en Ingeniería – Analítica
Medellín – 2023

Según vamos adquiriendo conocimiento, las cosas no se hacen más comprensibles, sino más misteriosas.

-Albert Schweitzer

Declaración de obra original


Yo declaro lo siguiente:

He leído el Acuerdo 035 de 2003 del Consejo Académico de la Universidad Nacional. «Reglamento sobre propiedad intelectual» y la Normatividad Nacional relacionada al respeto de los derechos de autor. Esta disertación representa mi trabajo original, excepto donde he reconocido las ideas, las palabras, o materiales de otros autores.

Cuando se han presentado ideas o palabras de otros autores en esta disertación, he realizado su respectivo reconocimiento aplicando correctamente los esquemas de citas y referencias bibliográficas en el estilo requerido.

He obtenido el permiso del autor o editor para incluir cualquier material con derechos de autor (por ejemplo, tablas, figuras, instrumentos de encuesta o grandes porciones de texto).

Por último, he sometido esta disertación a la herramienta de integridad académica, definida por la universidad.



Diego Camilo Mayorga Ballesteros

Fecha 31/01/2023

Agradecimientos

A todos aquellos que me han acompañado en este proyecto.

A mi compañera de vida Eliana que siempre me brinda su apoyo incondicional.

A mi amigo Sebastián, quien contribuyó en que este proyecto saliera adelante.

A mi familia por su comprensión y acompañamiento.

Al profesor Fernán, que bajo su guía tuve el apoyo necesario para culminar este trabajo.

Resumen

Diseño de un modelo de aprendizaje de máquina para reconocimiento y clasificación de daños en pavimento para vías de Sogamoso.

Este proyecto tiene como objetivo el desarrollo de un modelo de aprendizaje de máquina para reconocer y clasificar los daños en pavimentos. Se usaron técnicas de visión por computadora y aprendizaje, profundo se usó una red neuronal pre-entrenada (MobileNet) como punto de partida, este enfoque permitió una oportuna implementación del modelo y una reducción en el tiempo y los recursos necesarios para su entrenamiento. El rendimiento del modelo fue evaluado utilizando imágenes capturadas en el municipio de Sogamoso y se obtuvo un resultado aceptable en la detección y clasificación de daños en pavimentos. La herramienta desarrollada puede ser utilizada para la detección temprana de daños en las vías y para la toma de decisiones en la gestión de la infraestructura vial.

Palabras clave: daños en pavimentos, clasificación, reconocimiento, aprendizaje de máquina, aprendizaje profundo, transferencia de conocimiento

Abstract

Design of a machine learning model for recognition and classification of pavement damage for roads in Sogamoso.

This research project aims to develop a machine learning model to recognize and classify pavement damage. Computer vision and deep learning techniques were used, as a starting point, a pre-trained neural network (MobileNet) was used, this approach allowed a rapid implementation of the model and a reduction in the time and resources required for its training. The performance of the model was evaluated using images captured in Sogamoso and an acceptable result was obtained in the detection and classification of pavement damage. The developed tool can be used for the early detection of road damage and for decision-making in the management of road infrastructure.

Keywords: pavement damage, classification, recognition, machine learning, deep learning, transfer learning

Contenido

Contenido

| | |
|--|-----------|
| 1. Introducción..... | 15 |
| 1.1 Motivación..... | 15 |
| 1.2 Problema de investigación..... | 16 |
| 1.3 Objetivos..... | 16 |
| 1.3.1 Objetivo General..... | 16 |
| 1.3.2 Objetivo Especifico..... | 16 |
| 1.4 Alcance..... | 16 |
| 1.5 Revisión de la Literatura..... | 17 |
| 1.6 Discusión..... | 18 |
| 1.7 Metodología..... | 18 |
| 1.7.1 Comprensión del negocio..... | 19 |
| 1.7.2 Enfoque Analítico..... | 19 |
| 1.7.3 Requisitos de los datos..... | 19 |
| 1.7.4 Recolección de datos..... | 19 |
| 1.7.5 Entendimiento de los datos..... | 19 |
| 1.7.6 Preparación de los datos..... | 19 |
| 1.7.7 Modelamiento..... | 20 |
| 1.7.8 Evaluación..... | 20 |
| 1.7.9 Despliegue..... | 20 |
| 1.7.10 Retroalimentación..... | 20 |
| 2. Caracterización de imágenes y daños en pavimentos..... | 20 |
| 2.1 Introducción..... | 20 |
| 2.2 Descripción de daños en pavimentos..... | 21 |
| 2.3 Descripción de imágenes..... | 22 |
| 2.3.1 Región Geográfica..... | 22 |
| 2.3.2 Captura de imágenes..... | 23 |
| 2.3.3 Etiquetado..... | 24 |
| 2.4 Descripción del conjunto de datos..... | 25 |
| 3. Modelo de reconocimiento y clasificación de daños en pavimentos..... | 27 |
| 3.1 Introducción..... | 27 |
| 3.2 Transfer Learning..... | 28 |
| 3.3 Particionamiento de datos..... | 29 |
| 3.4 Evaluación del modelo..... | 30 |
| 3.5 Resultados..... | 31 |
| 4. Conclusiones y recomendaciones..... | 33 |
| 4.1 Conclusiones..... | 33 |
| 4.2 Recomendaciones..... | 33 |

Lista de figuras

| | |
|--|----|
| Figura 2-1 Ubicación geográfica Sogamoso | 22 |
| Figura 2-2 Vias donde se capturan imágenes | 23 |
| Figura 2-3 Software labellmg para anotación de imágenes | 24 |
| Figura 2-4 Ejemplos de imágenes anotadas..... | 24 |
| Figura 2-5 Ejemplo de archivo xml generados..... | 25 |
| Figura 2-6 D00 categoría más frecuente en Sogamoso..... | 25 |
| Figura 2-7 D00 es la categoría más frecuente en las imágenes del <i>dataset</i> RDD2022... | 26 |
| Figura 2-8 Distribución por país de categorías de daño..... | 26 |
| Figura 3-1 Transfer learning | 28 |
| Figura 3-2 Partición | 30 |
| Figura 3-3 métricas de evaluación..... | 30 |
| Figura 3-4 ejemplos de inferencias..... | 32 |

Lista de tablas

| | |
|--|----|
| Tabla 2-1 Descripción de tipos de daño en pavimentos flexibles | 21 |
| Tabla 3-1 métricas de evaluación | 31 |

Problemática de la detección de daños en pavimentos

1. Introducción

El mantenimiento de las vías es esencial para garantizar la seguridad de los conductores y pasajeros, una carretera en buen estado es mejor en términos de frenado, tracción y adherencia de los neumáticos, lo que reduce la probabilidad de accidentes. Es por ello por lo que se hacen grandes esfuerzos por monitorear el estado de las vías, sin embargo, la inspección manual de los daños en el pavimento es costosa en tiempo, recursos humanos y recursos económicos. Para resolver esta problemática, este trabajo propone una solución basada en *deep learning* para reconocer y clasificar los distintos tipos de daños en el pavimento, siguiendo las categorías sugeridas por el Instituto Nacional de vías (INVIAS 2006).

El modelo desarrollado cuenta con un rendimiento aceptable para ser usado en la monitorización del estado de las vías del municipio, para dicho propósito es necesario realizar la toma de fotografías de manera periódica en las vías principales del municipio, esto se puede lograr mediante una cámara dispuesta en algún vehículo que transite por las carreteras y autopistas, capturando imágenes que cubran toda la extensión del pavimento a analizar. Posteriormente, estas imágenes se procesan mediante el modelo de *deep learning* para detectar los daños en el pavimento y clasificarlos según su tipología. La detección temprana de los daños permitirá realizar el mantenimiento de manera oportuna antes de que se conviertan en una amenaza para la seguridad vial, además de reducir los costos asociados con la reparación de la carretera.

Por ejemplo, si al procesar las imágenes el modelo detecta una sección de la carretera con baches, los encargados podrían enviar un equipo de reparación para arreglarlos antes de que cause un accidente o el daño en el pavimento sea mayor y por ende más costoso de reparar. De esta manera, se pueden evitar situaciones peligrosas en las carreteras, como accidentes de tráfico, ya que los conductores tendrían una carretera más segura y en mejores condiciones para circular.

1.1 Motivación

La detección y clasificación precisa de los daños en el pavimento es fundamental para garantizar la seguridad y calidad de la infraestructura vial. Sin embargo, esta tarea requiere de grandes recursos económicos y humanos. En el municipio de Sogamoso, las estadísticas de la Agencia Nacional de Seguridad Vial (ANSV) muestran que, en el año 2021, este municipio tuvo una tasa alarmante de accidentes, siendo uno de los

departamentos con más accidentalidad en Boyacá después de la ciudad de Tunja. Entre las causas de estos accidentes, se incluyen el mal estado de las vías, así como factores relacionados con el comportamiento de los conductores y la cultura ciudadana (Agencia Nacional de Seguridad Vial, 2021).

1.2 Problema de investigación

La revisión sistemática de la literatura muestra que si bien, el problema de la detección y clasificación de daños en pavimentos se ha abordado desde diferentes enfoques, que van desde soluciones basadas en dispositivos especializados hasta el uso de algoritmos de *deep learning*, no se ha llegado a una solución generalizada que sea capaz de cumplir con los requerimientos técnicos para Colombia, donde el sistema de clasificación de daños es diferente, sin embargo, existe información de propuestas desarrolladas en diversos países las cuales pueden servir como insumo a la hora de desarrollar una solución más cercana a los requerimientos propios de Colombia y en el caso particular de este proyecto de la ciudad de Sogamoso.

1.3 Objetivos

1.3.1 Objetivo General

Diseñar un modelo para el reconocimiento y clasificación de daños en pavimento en las vías primarias, secundarias y nacionales de Sogamoso con el fin de monitorear la calidad de las vías y planeación de futuras reparaciones.

1.3.2 Objetivo Especifico

- Caracterizar las imágenes y variables requeridas para la clasificación de daños en pavimentos.
- Crear un conjunto de datos de imágenes correspondientes a daños en pavimentos de un sector de Sogamoso.
- Implementar un modelo de aprendizaje de máquina para reconocimiento y clasificación de daños en pavimentos.
- Validar el modelo implementado para reconocimiento y clasificación de daños en pavimentos.

1.4 Alcance

Este trabajo tendrá como fin el desarrollo de un modelo capaz de identificar el tipo de daño en pavimentos flexibles en vías ubicadas en Sogamoso, mediante la aplicación de un modelo de aprendizaje de máquina capaz de reconocer patrones de daño en imágenes tomadas en campo, con el fin de generar un sistema eficiente que permita monitorear el

estado del pavimento, y de esta forma clasificar rápidamente el grado de deterioro en las vías, lo cual permitiría tomar las medidas pertinentes de mantenimiento, mitigando el riesgo de accidentes y mejorando la calidad del servicio.

Los tipos de daño objeto del análisis son las fallas generadas por fisuras, deformaciones y pérdida de las capas de la estructura, en vías primarias, secundarias y nacionales que cruzan por la cabecera del municipio de Sogamoso. Por lo cual, se realizará un registro fotográfico en distintas zonas del municipio, utilizando *Google Street View* como fuente de datos principal.

1.5 Revisión de la Literatura

En el año 2005 Haroun Rababaah y su equipo, comparan diferentes modelos para resolver el problema de clasificación de daños en pavimentos mediante técnicas como perceptrón multicapa, algoritmos genéticos y mapas autoorganizados. Se encontró que el perceptrón multicapa tenía el mejor rendimiento en general (Arya, y otros, 2020).

En el año 2009 Y. Sun en el artículo titulado “*Automated pavement distress detection using advanced image processing techniques,*” utilizan métodos de procesamiento de imágenes para detectar los daños, pero solo de tipo transversal y longitudinal (Sun, Salari, & Chou, 2009).

En el año 2018 A. Ragnoli y su equipo describen los diferentes métodos que se han utilizado para desarrollar sistemas de detección de daños en el pavimento que incluyen encuestas manuales, sistemas mecánicos, sistemas basados en procesamiento de imágenes y uso de *deep learning* (Ragnoli, De Blasiis, & Di benedetto, 2018).

En el año 2019 R. Ronald, utilizaron técnicas de *deep learning* para realizar análisis del estado del pavimento, mediante el reconocimiento de imágenes identificando grietas aplicando redes neuronales convolucionales. Cuyo objetivo fue realizar monitoreo del estado de las vías con un costo bajo, y así llevar a cabo el mantenimiento y las reparaciones correspondientes antes de que los daños se aumenten (Roberts, Gaspare, Inzerillo, & Di Mino, 2020).

En el año 2020 Arya Deesha, desarrolló un modelo basado en redes neuronales para la clasificación de daños en el pavimento utilizando un *dataset* público que contiene 26620 imágenes etiquetadas provenientes de Japón, India y República Checa, con el fin de generar un modelo que funcione en diferentes países y cuya implementación sea sencilla y económica. Se encontró que el uso de imágenes de diferentes países puede ayudar a crear un modelo que generalice mejor y que tenga un rendimiento mayor sin embargo recomiendan utilizar datos locales (Rababaah, Vrajitoru, & Wolfer, 2005).

En el año 2021 Tello-Cifuentes y su equipo en su Tesis de pregrado describe el uso de redes neuronales para la clasificación de daños en pavimento, si bien hace uso de redes neuronales la tesis contiene algunos puntos débiles, como el uso de un *dataset* de tan solo

30 imágenes para entrenar la red neuronal, sin embargo, es el único estudio encontrado donde se aplica esta tecnología con datos colombianos (Tello-Cifuentes, Aguirre-Sánchez, Díaz-Paz, & Hernández, 2020).

1.6 Discusión

A pesar de que se han planteado diversas alternativas para abordar el problema, como soluciones basadas en dispositivos especializados o el uso de algoritmos de aprendizaje profundo, la realidad es que no se ha encontrado una solución universal que se adapte a los requisitos técnicos específicos de Colombia. Esto se debe a las condiciones particulares del país y al sistema de clasificación de daños en Colombia el cual es diferente al de otros países, lo que complica el proceso. Sin embargo, es posible utilizar propuestas de soluciones desarrolladas en otros países que pueden utilizarse como base para crear una solución más adecuada a las necesidades de Colombia y específicamente para el proyecto de la ciudad de Sogamoso.

1.7 Metodología

Se utilizó la metodología ASUM-DM *Analytics Solutions Unified Method* el cual es un modelo de trabajo ampliamente utilizado en el desarrollo de proyectos en las áreas de ciencia de datos principalmente. Este proporciona una serie de fases que al llevarse a cabo permiten la realización de un proyecto de forma eficaz y ordenada. En la siguiente imagen se muestra un esquema de todas las fases del proceso (Alianza Caoba, 2017):

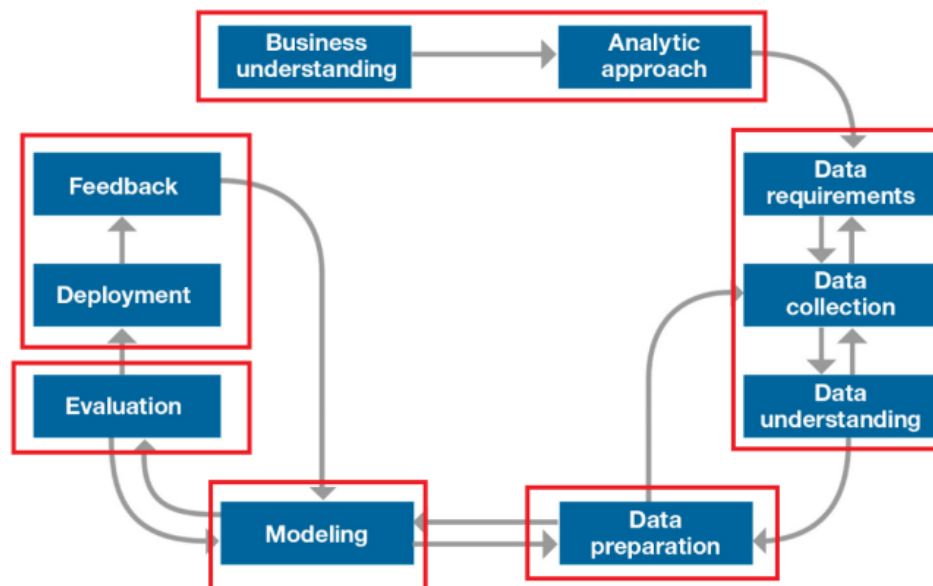


Figura 1-1 ASUM-DM

1.7.1 Comprensión del negocio

En esta primera etapa es necesario establecer el problema de negocio con el fin de que la solución esté alineada con los objetivos reales del caso, para este proyecto es necesario lograr el correcto monitoreo e inspección de daños en el pavimento lo cual requiere establecer algún mecanismo que permita determinar el tipo de daño en la vía.

1.7.2 Enfoque Analítico

En esta etapa el problema planteado se traduce en un problema técnico, así pues, debido a que se requiere clasificar y establecer la ubicación geográfica de los daños en el pavimento asfáltico, se desarrolló un producto de software capaz de realizar la clasificación del daño en imágenes previamente capturadas haciendo uso de un modelo de aprendizaje de máquina además de almacenar la información geográfica del daño en la vía.

1.7.3 Requisitos de los datos

De acuerdo con lo establecido en la fase anterior, es necesario contar con un conjunto de datos que contenga imágenes etiquetadas de acuerdo con el tipo de daño presente, estos datos permitirán el desarrollo de un modelo de aprendizaje de máquinas que se encargará del reconocimiento y clasificación de daños, es importante mencionar que para el desarrollo del modelo se requiere usar imágenes capturadas en la ciudad de Sogamoso esto con el fin de mejorar la calidad de la clasificación.

1.7.4 Recolección de datos

Para la recolección de los datos es necesario capturar imágenes de daños en pavimentos ubicados en vías de la ciudad de Sogamoso, para ello se usó la cámara de celular para la toma de imágenes.

1.7.5 Entendimiento de los datos

Una vez se realiza la recolección de los datos es necesario evaluar la calidad de estos, para ellos se realizó un proceso de revisión con el fin de establecer cuáles imágenes son pertinentes y cuales no deben hacer parte del conjunto de datos final.

1.7.6 Preparación de los datos

Es necesario aplicar las técnicas de preprocesado y estandarización de las imágenes capturadas según sea el caso, esto con el fin de construir un conjunto de datos de calidad, dicho proceso consistió en igualar la resolución y el esquema de colores de las imágenes.

1.7.7 Modelamiento

Partiendo de la primera versión del conjunto de datos se desarrolló un modelo de aprendizaje de máquina capaz de realizar el reconocimiento y clasificación de daños en el pavimento mediante imágenes, esta etapa fue iterativa donde el desarrollo del modelo influyó en como se realizó preparación de los datos y la selección de parámetros del modelo.

1.7.8 Evaluación

Es necesario evaluar la calidad del modelo de clasificación para ello se reservó una porción de las imágenes capturadas y se cuantificó la calidad de la clasificación mediante métricas pertinentes como *IoU* y *f1-score*.

1.7.9 Despliegue

El modelo se almacena para ser utilizado en el conjunto de testeo y de esta manera replicar un despliegue real de la solución.

1.7.10 Retroalimentación

Ya en la etapa de despliegue es necesario tomar en cuenta cualquier información de valor que pueda llegar a sugerir algún ajuste o cambio en el planteamiento o desarrollo de la solución presentada.

2. Caracterización de imágenes y daños en pavimentos

2.1 Introducción

Para este trabajo fue necesario recopilar imágenes de daños en pavimentos en el municipio de Sogamoso, ya que al incluir datos del mismo lugar donde se pretende implementar el modelo puede llegar a mejorar el rendimiento de este. Una vez se capturan las imágenes es necesario realizar el correcto etiquetado de estas, para ello se decidió utilizar algunas de las distinciones que sugiere en INVIAS para la correcta clasificación de daños en pavimentos (Agencia Nacional de Seguridad Vial, 2021).

2.2 Descripción de daños en pavimentos

Dentro de los lineamientos descritos por en INVIAS para la inspección visual de pavimentos existe una categorización del tipo de daño, dentro de los tipos de deterioro se hace especial distinción entre grietas longitudinales (D00), grietas transversales (D10), piel de cocodrilo (D20) y baches (D40) ya que son los tipos de daño más comunes y de fácil reconocimiento visual.

| Daño | Descripción | Ejemplo |
|------------------------------|---|---|
| Grietas longitudinales (D00) | Corresponde a la categoría de daños por fisura, y se caracterizan por ser discontinuidades en la misma dirección del tránsito. |  |
| Grietas transversales (D10) | Corresponde a la categoría de daños por fisura, y se caracterizan por ser discontinuidades transversales a la dirección del tránsito. |  |
| Piel de cocodrilo (D20) | Se trata de una serie de fisuras conectadas entre sí que se propagan en patrones angulares |  |
| Baches (D40) | Se trata de una desintegración del pavimento, dejando parcial o totalmente expuesta la capa granular |  |

Tabla 2-1 Descripción de tipos de daño en pavimentos flexibles.

Con el fin de entrenar un modelo capaz de reconocer y clasificar daños en pavimentos dentro de las categorías previamente descritas, es necesario contar con un conjunto de datos que consta de imágenes y su anotación correspondiente, donde se indique dónde está el daño y a que categoría pertenece de acuerdo con la clasificación de la Tabla 2-1.

Se utilizaron dos fuentes principales para crear un conjunto de datos sólido para entrenar un modelo. Primero, se empleó un *dataset* público que incluía imágenes capturadas en diferentes países. Además, se generó un *dataset* exclusivo con imágenes de la zona metropolitana de Sogamoso.

2.3 Descripción de imágenes

2.3.1 Región Geográfica

La ciudad de Sogamoso es una importante ubicación en el departamento de Boyacá, situado en la región central oriental de Colombia. A solo 220 km de Bogotá y 76 km de Tunja, capital de Boyacá, Sogamoso es accesible y bien conectado. Con una temperatura promedio de 17 grados en la Figura 2-1 se muestra la ubicación de Sogamoso.



Figura 2-1 Ubicación geográfica Sogamoso

2.3.2 Captura de imágenes

Para la construcción del conjunto de datos que contiene imágenes de Sogamoso fue necesario hacer uso de *Google Street View*, donde se fue recorriendo el área metropolitana de Sogamoso capturando imágenes donde fuera evidente algún tipo de deterioro en el pavimento. Todas las imágenes fueron estandarizadas en una resolución de 640 x 640 píxeles y *dataset* completo se encuentra almacenado en un repositorio de [GitHub](#).




Figura 2-2 Vías donde se capturan imágenes

Con el fin de tener un mejor entendimiento de la red vial del municipio fue necesario recorrer los diferentes sectores de la ciudad incluyendo las vías principales y secundarias, en la Figura 2-2 se puede observar los sectores recorridos también se observa que cerca del 20% de las vías del casco urbano del municipio de Sogamoso fueron tenidas en cuenta a la hora de capturar las imágenes.

2.3.3 Etiquetado

Para el etiquetado de las imágenes recolectadas en Sogamoso se hizo uso del software libre *Labellmg* donde se ubica y clasifica manualmente cada uno de los daños presentes en una imagen dada, a continuación, se muestran a modo de ejemplo algunas etiquetas realizadas.




Figura 2-3 Software labellmg para anotación de imágenes

En la Figura 2-3 se observa un ejemplo de etiquetado donde los puntos verdes representan los vértices de las cajas de detección esperadas.



Figura 2-4 Ejemplos de imágenes anotadas

En la Figura 2-4 se pueden ver algunos ejemplos de la anotación llevada a cabo mediante *Labellmg*, por otra parte, el *software* genera un archivo xml por cada imagen etiquetada, en este archivo se especifican las coordenadas de cada caja de detección, así como la correspondiente etiqueta para clasificación, a continuación, en la Figura 2-5 se muestra un ejemplo del archivo xml generado.

```

1 <annotation>
2   <folder>Etiquetado</folder>
3   <filename>465.PNG</filename>
4   <path>C:\Users\diemayba\Desktop\resolucion\Etiquetado\465.PNG</path>
5   <source>
6     <database>Unknown</database>
7   </source>
8   <size>
9     <width>640</width>
10    <height>640</height>
11    <depth>3</depth>
12  </size>
13  <segmented>0</segmented>
14  <object>
15    <name>D20</name>
16    <pose>Unspecified</pose>
17    <truncated>0</truncated>
18    <difficult>0</difficult>
19    <bndbox>
20      <xmin>205</xmin>
21      <ymin>570</ymin>
22      <xmax>260</xmax>
23      <ymax>637</ymax>
24    </bndbox>
25  </object>
26 </annotation>

```

Figura 2-5 Ejemplo de archivo xml generados

2.4 Descripción del conjunto de datos.

El conjunto de datos generado a partir de la recolección de imágenes en Sogamoso cuenta con un total de 513 imágenes etiquetadas, mientras que el conjunto de datos RDD2022 cuenta con cerca de 38000 imágenes etiquetadas.

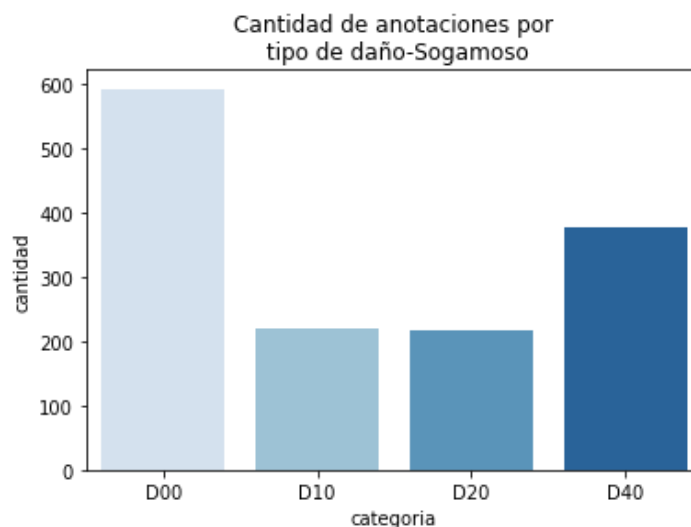


Figura 2-6 D00 categoría más frecuente en Sogamoso

Como se puede ver en la Figura 2-6 de las imágenes obtenidas en Sogamoso, la categoría más frecuente es la D00 que corresponde a grietas longitudinales, seguida por la categoría D40 que corresponde a Baches. Por otra parte, en el *dataset* RDD2022, también se tiene como categoría más frecuente las grietas longitudinales, pero por el contrario la categoría con menos frecuencia es la D40.




Figura 2-7 D00 es la categoría más frecuente en las imágenes del *dataset* RDD2022

Al ver la distribución del tipo de daño por país, es posible notar que hay una tendencia donde el tipo de daño más frecuente es la grieta longitudinal D00, esto aplica para todos los países evaluados a excepción de la India, donde existe una mayor cantidad de etiquetas relacionadas con baches D40.

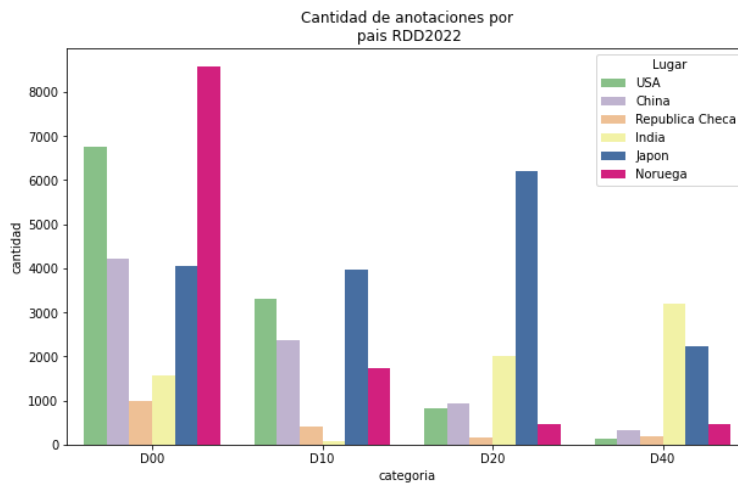


Figura 2-8 Distribución por país de categorías de daño

3. Modelo de reconocimiento y clasificación de daños en pavimentos

3.1 Introducción

El *deep learning* es un subcampo de la inteligencia artificial que se basa en el uso de redes neuronales artificiales profundas (*deep neural networks*) para resolver problemas complejos de aprendizaje automático.

Estas redes neuronales profundas están compuestas por muchas capas de nodos interconectados, cada uno de los cuales realiza una operación matemática simple en la entrada, y se combinan para producir una respuesta final. El aprendizaje se realiza ajustando los pesos de las conexiones entre nodos, a medida que se proporciona información de entrenamiento.

El *deep learning* es especialmente útil en la resolución de problemas que requieren la identificación de patrones complejos en grandes cantidades de datos, como la clasificación de imágenes, el reconocimiento de voz y la generación de texto.

Por otra parte, el *transfer learning* es un enfoque de aprendizaje de máquina que permite reutilizar una red neuronal pre-entrenada en una tarea específica, en lugar de entrenar una red neuronal desde cero.

En este caso, se utilizó *transfer learning* para crear un modelo de detección y clasificación de daños en pavimentos. Esto significa que se partió de una red neuronal *pre-entrenada* entre otras tareas relacionadas con la visión por computadora, y se modificaron y ajustaron los pesos de las conexiones para que el modelo fuera capaz de realizar la tarea específica de detección y clasificación de daños en pavimentos.

Este enfoque puede resultar en una implementación oportuna en menor tiempo y recursos de entrenamiento, ya que la red ya tiene un conocimiento previo sobre cómo procesar imágenes y detectar patrones.

3.2 Transfer Learning

El problema de reconocimiento y clasificación de pavimentos a través de imágenes se enmarca en la ciencia de datos en el campo de la visión por computadora. Para este problema se hizo uso de la técnica de *transfer learning*, donde se emplea un modelo previamente entrenado con datos genéricos y que posteriormente se puede entrenar nuevamente para ajustar su rendimiento al problema específico en cuestión.

Mediante *TensorFlow* es posible hacer uso de modelos previamente entrenados, como es el caso del modelo *SSD MobileNet V2* el cual fue usado como base para el modelo de reconocimiento y clasificación de daños desarrollado.

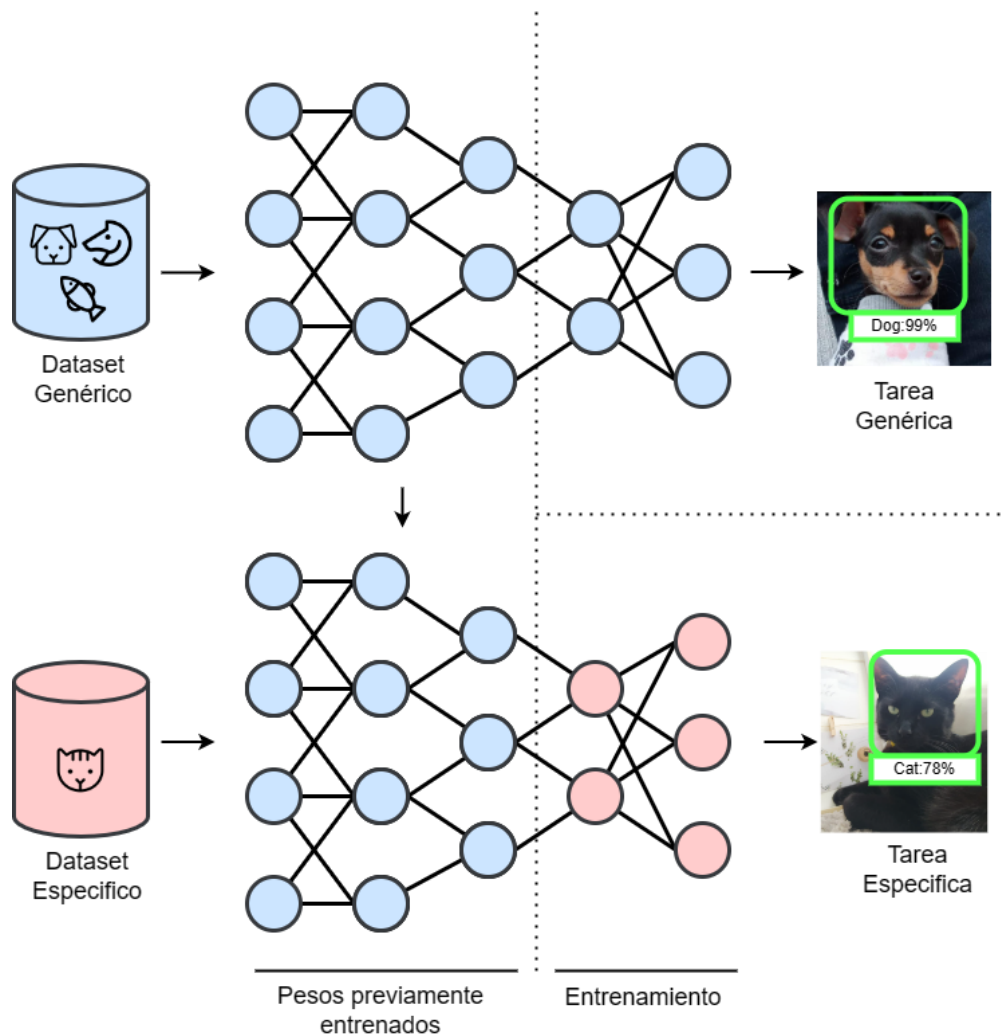


Figura 3-1 Transfer learning

Aquí hay un resumen de los pasos para realizar *transfer learning* con *MobileNet* en *TensorFlow*:

1. Cargar la red neuronal pre-entrenada de *MobileNet*: Se puede cargar *MobileNet* desde el *Model Zoo* de *TensorFlow* para modelos pre-entrenados
2. Ajustar la estructura de la red: A continuación, se puede modificar la estructura de la red, como el número de capas o el número de salidas, para adaptarse a la tarea específica.
3. Congelar las capas: Es posible congelar las capas de la red neuronal pre-entrenada para evitar que se ajusten durante el entrenamiento.
4. Entrenar la red: Una vez que la red está lista para ser entrenada, se puede utilizar un conjunto de datos de entrenamiento etiquetado para ajustar los pesos de la red y mejorar su rendimiento en la tarea específica, en este caso la detección y clasificación de daños en pavimento.
5. Evaluar el rendimiento: Por último, se puede evaluar el rendimiento del modelo en un conjunto de datos de prueba para verificar su capacidad para detectar y clasificar los daños en pavimentos.

3.3 Particionamiento de datos.

Para ajustar el modelo de manera adecuada fue necesario probar con diferentes particiones de los datos, siendo el uso de datos combinados entre el *dataset* RDD2022 específicamente las imágenes recolectadas en USA con las imágenes recolectadas en el municipio de Sogamoso.

Debido a las diferentes condiciones presentes en cada país en cuanto a la calidad y deterioro del pavimento flexible se realizaron pruebas para encontrar un modelo que tuviera un rendimiento aceptable a la hora de aplicarse en un entorno como el que sería la ciudad de Sogamoso, siendo el uso de imágenes de Estados Unidos y Colombia la combinación que mejor funcionó a la hora de calibrar el modelo, a continuación, mediante la Figura 3-2 se describe dicha partición.

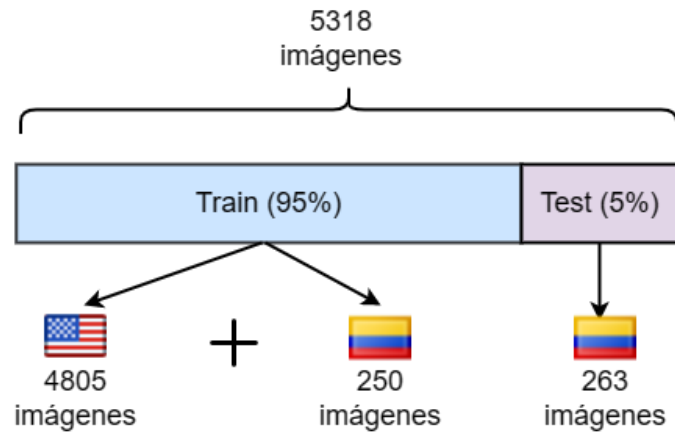


Figura 3-2 Partición

3.4 Evaluación del modelo.

Para evaluar el modelo se implementaron dos métricas principales el F_1 score y el IoU (*Intersection over Union*), la elección de la métrica F_1 para la evaluación del modelo está basada en el hecho de que los datos no son balanceados existiendo una mayor cantidad de etiquetas para algunas categorías frente a otras, con esta métrica es posible evaluar la calidad de la clasificación que realiza el modelo. Por otra parte, la métrica IoU es un buen indicativo de la calidad de la detección de daños, con esta métrica es posible tener una idea de que tan cercana es la caja de detección inferida por el modelo frente a la caja realizada en la detección manual.

$$F_1 = 2 \frac{(\textit{precision} \times \textit{recall})}{(\textit{precision} + \textit{recall})}$$

$$IoU = \frac{\textit{Área de la intersección}}{\textit{Área de la unión}}$$



$$IoU = \frac{\textit{Área intersección}}{\textit{Área Unión}} = \frac{\text{Diagrama de intersección}}{\text{Diagrama de unión}}$$

Diagrama de intersección: Dos rectángulos azules que se solapan, con la zona común rodeada por una línea roja discontinua.

Diagrama de unión: Los mismos dos rectángulos azules, con el área total que ocupan rodeada por una línea roja discontinua.

Figura 3-3 métricas de evaluación

En la Figura 3-3 se esquematiza la métrica Intersección sobre Unión (IoU) la cual es una medida de la similitud entre dos regiones en una imagen. La IoU mide el porcentaje de *overlap* entre la región predicha por el modelo y la región verdadera del objeto en la imagen. Se calcula como la relación entre la intersección de las dos regiones y la unión de estas. Una IoU alta indica una coincidencia estrecha entre la región predicha y la verdadera, lo que significa un buen desempeño del modelo. Por otro lado, una IoU baja indica una coincidencia débil y, por lo tanto, un mal desempeño del modelo.

3.5 Resultados

Una vez el modelo es entrenado se procede a calcular las métricas de evaluación para el conjunto de test, es importante recordar que el conjunto de test está compuesto por datos de Sogamoso únicamente por lo tanto estas métricas son un buen estimativo del rendimiento del modelo en un despliegue real en el municipio, el código necesario para el entrenamiento y evaluación del modelo se encuentra en [GitHub](#). A continuación, en la tabla 3-1 se muestran algunos resultados:

| Modelo | F1 Test | IoU Test |
|---------------------------------|---------------|---------------|
| SSD MobileNet V2 640x640 | 0.4123 | 0.6421 |
| EfficientDet D1 640x640 | 0.3621 | 0.5620 |
| SSD MobileNet v2 320x320 | 0.3211 | 0.5921 |
| EfficientDet D0 512x512 | 0.2967 | 0.5638 |

Tabla 3-1 métricas de evaluación

El modelo con mejor rendimiento fue MobileNet V2 640x650 el cuenta con las siguientes ventajas:

1. Rapidez: *MobileNet V2* es una red neuronal ligera y rápida, por lo que el modelo SSD es adecuado para ser ejecutado en dispositivos con recursos limitados, como smartphones o cámaras.
2. Precisión: *SSD MobileNet V2* es conocido por ser un modelo preciso en la detección y clasificación de objetos.

3. Ahorro de recursos: *MobileNet V2* es una red neuronal de bajo consumo de recursos, por lo que el modelo SSD *MobileNet V2* es adecuado para ser entrenado con pequeñas cantidades de datos.
4. Funcionamiento en tiempo real: SSD *MobileNet V2* es adecuado para funcionar en tiempo real.
5. Facilidad de implementación: *MobileNet V2*

En la Figura 3-4 se puede observar algunos ejemplos de inferencias realizadas por el modelo entrenado, donde se hace una correcta clasificación de los principales daños presentes en la vía. En la caja de detección se puede observar la clasificación realizada y el nivel de confianza con el que la red neuronal hace la inferencia.

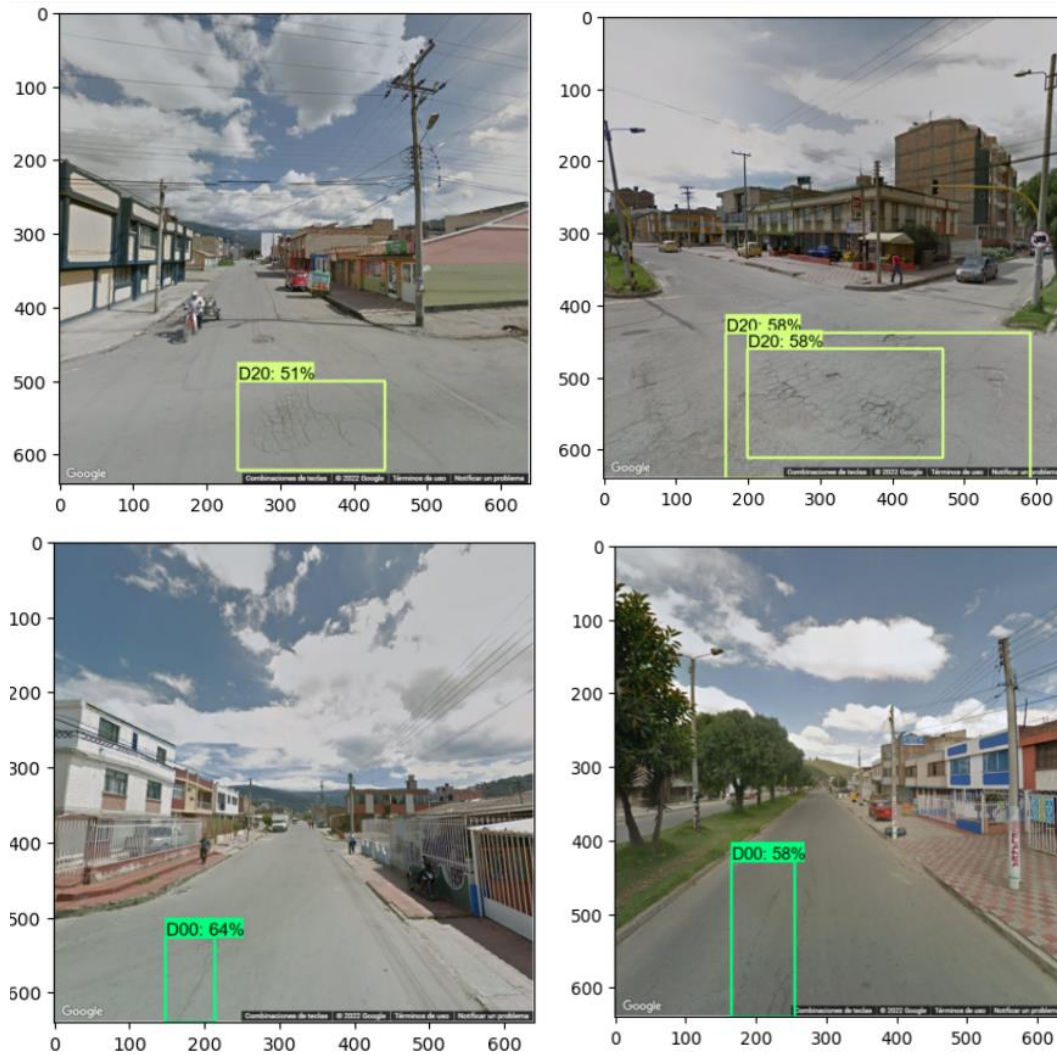


Figura 3-4 ejemplos de inferencias

4. Conclusiones y recomendaciones

4.1 Conclusiones

Se logró diseñar un modelo de reconocimiento y clasificación de daños en pavimentos en las vías primarias, secundarias y nacionales de Sogamoso mediante el uso de técnicas de aprendizaje de máquina. Al evaluar el modelo en el conjunto de testeo se midió un rendimiento aceptable dadas las dificultades técnicas del problema asociadas principalmente con la gran variabilidad que puede existir en las imágenes capturadas (clima, iluminación, tráfico, estado del pavimento, entre otras). Para el caso específico del municipio de Sogamoso se encontró que el base el modelo SSD MobileNet V2 640x640 fue el de mejor rendimiento.

Se caracterizaron las imágenes y variables necesarias para la clasificación de daños en pavimentos, lo que permitió la creación de un conjunto de datos propio con imágenes capturadas en el municipio de Sogamoso, lo que asegura que el modelo tenga una mayor precisión y esté mejor adaptado a las condiciones específicas de la zona.

Se implementó el modelo desarrollado detectando y clasificando danos en pavimento presentes en las imágenes capturadas en el municipio de Sogamoso, al implementar el modelo con imágenes propias del municipio fue posible estimar su rendimiento para aplicaciones reales.

Finalmente, se validó el modelo desarrollado mediante la realización de pruebas y comparaciones con otras técnicas de clasificación de daños en pavimentos, demostrando que el modelo creado es una herramienta útil y efectiva para el monitoreo y la planificación de reparaciones en las vías del municipio de Sogamoso.

4.2 Recomendaciones

Dada la gran variabilidad que se puede presentar a la hora de clasificar imágenes de daños en pavimentos, una buena opción para mejorar el rendimiento del modelo es alimentar el conjunto de datos con una mayor cantidad de imágenes en diferentes entornos y condiciones climáticas, horarias, etc. También se recomienda evaluar el uso de técnicas como *image augmentation* con el fin de acrecentar artificialmente la cantidad de imágenes para el entrenamiento.

Bibliografía

- Agencia Nacional de Seguridad Vial. (2021). Boletín estadístico Boyacá, fallecidos y lesionados por siniestros viales, serie departamentos, Enero - Mayo 2021. Boyacá.
- Alianza Caoba. (2017). Perfil Alianza Caoba - Reporte técnico. Bogotá D.C.: Universidad de los Andes.
- Arya, Deeksha and Maeda, Hiroya and Ghosh, Sanjay Kumar and Toshniwal, Durga and Sekimoto, Yoshihide (2022) RDD2022: A multi-national image dataset for automatic Road Damage Detection.
- Arya, D., Maeda, H., Kumar Ghosh, S., Toshniwal, D., Mraz, A., Kashiyama, T., & Sekimoto, Y. (2020). Transfer Learning-based Road Damage Detection for Multiple Countries.
- INVIAS 2006, Estudio e investigación del estado actual de las obras de la red nacional de carreteras- Manual para la inspección de pavimentos flexibles
- Nicholas Renotte (2021). Tensorflow Object Detection Course. GitHub-nicknochnack/TFODCourse
- Rababaah, H., Vrajitoru, D., & Wolfer, J. (2005). ASPHALT PAVEMENT CRACK CLASSIFICATION: A COMPARISON OF GA, MLP, AND SOM. South Bend, Indiana.
- Ragnoli, A., De Blasiis, M. R., & Di benedetto, A. (2018). Pavement Distress Detection Methods: A Review. *infrastrutures*, 3(4), 58.
- Roberts, R., Gaspare, G., Inzerillo, L., & Di Mino, G. (2020). Towards Low-Cost Pavement Condition Health Monitoring and Analysis Using Deep Learning. *applied sciences*, 10(1), 319.
- Siete días Boyacá. (18 de junio de 2019). Siete días Boyacá. Obtenido de Siete días Boyacá: <https://boyaca7dias.com.co/2019/06/18/sogamoso-tiene-la-cifra-mas-alta-de-accidentalidad-en-el-departamento>

- Sun, Y., Salari, E., & Chou, E. (2009). Automated pavement distress detection using advanced image processing techniques. 2009 IEEE International Conference on Electro/Information Technology, (págs. 373-377). doi:10.1109/EIT.2009.5189645.
- Tello-Cifuentes, L., Aguirre-Sánchez, M., Díaz-Paz, J. P., & Hernández, F. (2020). Damage Evaluation in Flexible Pavement Using Terrestrial Photogrammetry and Neural Networks. *Tecnológicas*, 24(50).
- Universidad Nacional de Colombia. (2006). Manual para la inspección visual de pavimentos flexibles. Bogotá D.C.: Universidad Nacional de Colombia.