



Análisis de incidentes de tránsito mediante la calidad del modelo KNN

Analysis of traffic incidents using the quality of the KNN model

Análise de incidentes de trânsito usando a qualidade do modelo KNN

Mario Gerardo Moreno-Pallares ^I
mario.moreno01@epn.edu.ec
<https://orcid.org/0000-0001-9083-8816>

Rodrigo Rigoberto Moreno-Pallares ^{II}
rodrigo.moreno@epoch.edu.ec
<https://orcid.org/0000-0003-1877-6942>

Correspondencia: mario.moreno01@epn.edu.ec

Ciencias técnicas y aplicadas
Artículo de revisión

***Recibido:** 30 de septiembre de 2020 ***Aceptado:** 29 de octubre de 2020 * **Publicado:** 18 de noviembre de 2020

- I. Ingeniero en Sistemas Informáticos, Escuela Politécnica Nacional, Riobamba, Ecuador.
- II. Magister en Ingeniería Industrial y Productividad Msc, Ingeniero Industrial, Formación de Formadores, Escuela Superior Politécnica de Chimborazo, Riobamba, Ecuador.

Resumen

El presente estudio es una investigación referente a la clasificación de incidentes de tránsito, los cuales se encuentran plasmados en videos por parte de cámaras ya sean de seguridad u otro dispositivo de video, con la ayuda de las nuevas tecnologías informáticas se encuentran resultados con un alto nivel de porcentaje de exactitud, con los datos obtenidos y el modelo de clasificación correspondiente podemos dar una predicción de los incidentes suscitados en el lugar donde ocurren estos actos de riesgos que afectan a conductores, peatones y la propiedad tanto pública como privada, las tecnologías de KNN con datos en crudo y normalizados, SSD Mobilenet ayuda a detectar los automóviles y su seguimiento lo realizamos con la técnica del centroide en los videos recolectados, esto ayuda a tener una mejor perspectiva del comportamiento de los incidentes en cualquier lugar geográfico donde exista demasiado trafico o que siempre ocurran riesgos de incidentes, para que autoridades y encargados de la seguridad vial puedan tomar mejores decisiones y poder disminuir la tasa de crecimientos de incidentes de tránsito.

Palabras claves: Incidente; informática; seguridad vial; detección; machine learning; inteligencia artificial; tracking.

Abstract

This study is an investigation related to the classification of traffic incidents, which are captured in videos by security cameras or another video device, with the help of new computer technologies, results with a high level of percentage of accuracy, with the data obtained and the corresponding classification model we can give a prediction of the incidents arising in the place where these acts of risk occur that verify drivers, pedestrians and both public and private property, the technologies of KNN with raw and normalized data, SSD Mobilenet helps detect cars and their monitoring is carried out with the centroid technique in the videos collected, this helps to have a better perspective of the behavior of incidents in any geographical place where there is traffic or risks of incidents always occur, so that authorities and those in charge of the road safety can make better decisions and be able to reduce the growth rate of traffic incidents.

Keywords: Incident; it; road safety; detection; machine learning; artificial intelligence; tracking.

Resumo

Este estudo é uma investigação relacionada à classificação dos incidentes de trânsito, que são capturados em vídeos por câmeras de segurança ou outro dispositivo de vídeo, com o auxílio de novas tecnologias de informática, resultados com alta nível de percentagem de precisão, com os dados obtidos e o modelo de classificação correspondente podemos dar uma previsão dos incidentes ocurridos no local onde ocorrem estes atos de risco que afetam motoristas, peões e bens públicos e privados, as tecnologias de KNN com dados brutos e normalizados, SSD Mobilenet auxilia na detecção de carros e seu monitoramento é realizado com a técnica de centróide nos vídeos coletados, o que ajuda a ter uma melhor perspectiva do comportamento de incidentes em qualquer local geográfico onde haja muito tráfico ou que sempre ocorrem riscos de incidentes, de modo que autoridades e gestores da segurança no trânsito pode tomar melhores decisões e ser capaz de reduzir a taxa de crescimento de incidentes de trânsito

Palavras-chave: Incidente; Informática; segurança rodoviária; detecção; aprendizado de máquina; inteligência artificial; rastreamento.

Introducción

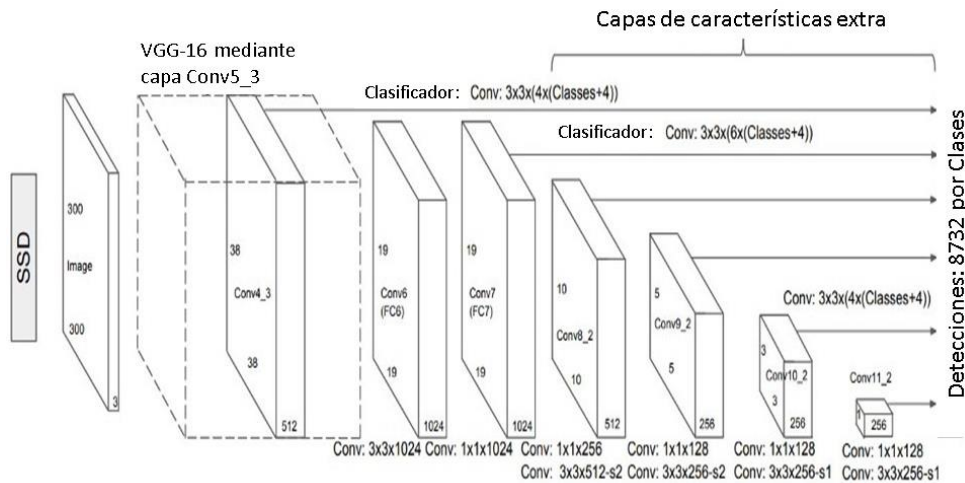
Según la ANT, en el presente periodo del año 2020 se tiene un total de 11488 siniestros de tránsito, lesionados y fallecidos, el cual es diferente al año 2019 con 24595, este fenómeno ocurre por la pandemia que estamos pasado pero si observamos los datos del 2008 en adelante estos suben cada año, loas cuales son datos muy preocupantes, las carreteras y arterias viales de cualquier orden ayudan al desplazamiento tanto de personas como mercancías, y cada vez el aumento significativo de vehículos de todo tipo ayudan a que los incidentes de tránsito aumenten [1], el factor más destacado para que esto ocurra es la velocidad con la que cada vehículo circula en las carreteras este es un factor que determina el tipo de incidente que puede existir [22], y estos factores no solamente son problema esto ocurre en todo el mundo como es el caso de la Región Andina donde se han producido alrededor de 127 decesos por cada millón de habitantes causado por siniestros automovilísticos en la Unión Europea se registra 50 fallecidos por millón de habitantes [3] .

Materiales y métodos

Se utilizaron videos tanto caseros como videos profesionales, el clasificador SSD MobileNet [4] el modelo se basa en una red convolucional de retro propagación, la que produce un conjunto

de BBs y puntajes de instancia de clases al existir presencia de este, en la Figura 2.6.2.1, BB predeterminados y relaciones de aspecto. Esta red ha sido entrenada con PASCAL, COCO e ILSVRC [5].

Figura1: Arquitectura SSD.



MobileNet se usa en aplicaciones de visión integral y en móviles. Esta red fue entrenada en TensorFlow usando RMSprop con el método de descenso de gradiente, se usa pocas técnicas de regularización y aumentación de datos. MobileNet tiene 28 capas de profundidad con 4.2 millones de parámetros que es el más pequeño de los modelos disponibles, además utilizan el multiplicador de ancho y de resolución para hacerlo aún más pequeño.

El rastreador usa los centroides de los BBs los que son calculados por medio de sumas ponderadas de los puntos del borde de dicho BB perteneciente a cada objeto detectado, el uso de centroides hace a este seguidor más robusto de acuerdo a la oclusión y su desplazamiento. [6].

Al hacer un seguimiento con centroides el límite del objeto se lo aproximara mediante una curva paramétrica definida como una suma ponderada de funciones básicas b_1, \dots, b_n , que puede ser representado como:

$$z(s) = \sum_{k=1}^N z_k b_k(s)$$

$$x(t) = Ax(t - 1) + w(t)$$

Ecuación 16: Representación dinámica del movimiento

Conjunto de datos recolectado

Se utilizaron tres bases de datos para el respectivo estudio.

Tabla 1: Bases de datos utilizadas

Descripción	Número de videos	Duración
Incidentes	68	1011.84 segundos (16 minutos, 51 segundos)
No Incidentes	148	34698.76 segundos (9 horas, 38 minutos, 24 segundos)
Total	216	9 horas 55 minutos 15 segundos

Diagrama de la estimación de la velocidad de cada automóvil del conjunto de datos

Figura 2: Diagrama de la estimación de la velocidad

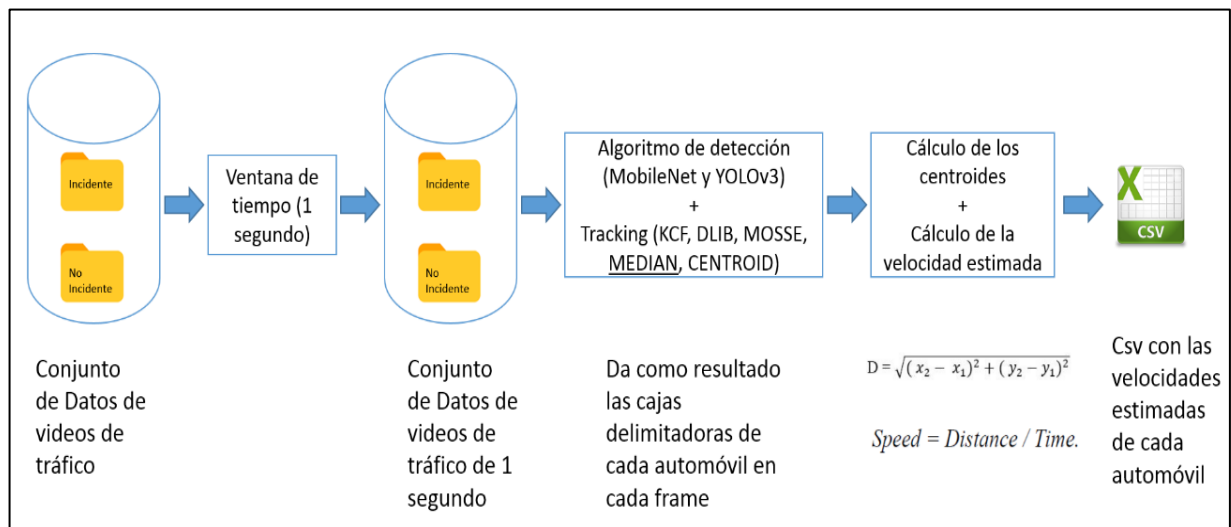
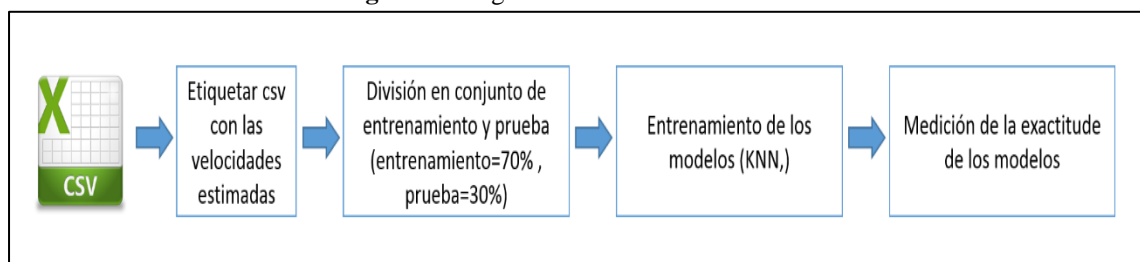


Diagrama de entrenamiento de modelos de machine learning

Figura 3: Diagrama de entrenamiento



Resultados

Tabla 2: Resultados del modelo

METRICA DE EXACTITUD DE CADA MODELO CREADO		
	MOBILENET	
		CENTROIDE
KNN	DATOS EN CRUDO	0.97
	DATOS NORMALIZADOS	0.97
METRICA AREA BAJO LA CURVA DE CADA MODELO CREADO		
	MOBILENET	
		CENTROIDE
KNN	DATOS EN CRUDO	0.80
	DATOS NORMALIZADOS	0.53

Los resultados obtenidos en el estudio con el modelo estimado tenemos que la exactitud del modelo es del 97 % como se muestra en el cuadro, mientras tanto que la métrica área bajo la curva ROC indica que el 80% de los incidentes de tráfico son identificados dentro del conjunto de entrenamiento.

Conclusiones

Con los datos recogidos el mejor modelo es el clasificador KNN entrenado con datos en crudo, ya que es un cumple con una exactitud alta al igual que su AUC ROC que son métricas que aseguran la seguridad de este.

En este caso el conjunto de datos tiene un desbalance por lo que el modelo KNN cuenta como un modelo preciso por su técnica de elección de vecinos más cercanos en este caso predice con gran exactitud porque existen dos grupos diferentes de datos.

Referencias

1. Z. Han, J. Liang, and J. Li, “Design of Intelligent Road Recognition and Warning System for Vehicles Based on Binocular Vision,” *IEEE Access*, vol. 6, pp. 62880–62889, 2018.
2. MINISTERIO DE TRANSPORTE Y OBRAS PÚBLICAS DEL ECUADOR, “Consecuencias del exceso de velocidad | Servicio Público para Pago de Accidentes de Tránsito.” [Online]. Available: <https://www.protecciontransito.gob.ec/servicios/consecuencias-del-exceso-de-velocidad/>. [Accessed: 04-Feb-2020].
3. Banco Interamericano de desarrollo, “Conceptos prácticos para la implementación de,” vol. 1, p. 22, 2019.
4. Y. Xiao et al., A review of object detection based on deep learning, vol. 79, no. 33–34. *Multimedia Tools and Applications*, 2020.
5. W. Liu et al., “SSD: Single shot multibox detector,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 9905 LNCS, pp. 21–37, 2016.
6. J. C. Nascimento, A. J. Abrantes, and J. S. Marques, “Algorithm for centroid-based tracking of moving objects,” *ICASSP, IEEE Int. Conf. Acoust. Speech Signal Process. - Proc.*, vol. 6, no. 1, pp. 3305–3308, 1999.

©2020 por los autores. Este artículo es de acceso abierto y distribuido según los términos y condiciones de la licencia Creative Commons Atribución-NoComercial-CompartirIgual 4.0 Internacional (CC BY-NC-SA 4.0) (<https://creativecommons.org/licenses/by-nc-sa/4.0/>).