

UNIVERSIDAD AUTÓNOMA DE ZACATECAS

“Francisco García Salinas”



**DETECCIÓN DEL USO DEL CASCO EN CONDUCTORES DE
MOTOCICLETA, UTILIZANDO REDES NEURONALES
CONVOLUCIONALES**

Tesis para obtener el grado de:

Maestro en Ciencias del Procesamiento de la Información

Presenta

I.A. Jaime Mercado Reyna

Director:

Dr. Huizilopoztli Luna García

Co-Directores:

Dr. José María Celaya Padilla

Dr. William Joseph Giraldo Orozco

Asesores:

Dr. Antonio Martínez Torteya

Dr. Gamaliel Moreno Chávez

Zacatecas, Zac., noviembre 2023.



SOMOS
ARTE, CIENCIA Y
DESARROLLO
CULTURAL



Zacatecas, Zac., 22 de noviembre de 2023.

C. Jaime Mercado Reyna
Estudiante de la MCPI
PRESENTE

At'n: Dr. Huizilopoztli Luna García
Responsable de la MCPI

Nos es grato comunicarle que después de haber sometido a revisión académica la propuesta de Tesis titulada "**Detección del Uso del Casco en Conductores de Motocicleta Utilizando Redes Neuronales Convolucionales**", presentada por el estudiante Ing Jaime Mercado Reyna y habiendo efectuado todas las correcciones indicadas por este Comité Tutorial, se **AUTORIZA** el documento de tesis para su impresión.

Sin más por el momento reciban un cordial saludo.

COMITÉ TUTORIAL
PROCESAMIENTO Y ANÁLISIS DE DATOS

Dr. Huizilopoztli Luna García

Dr. William Joseph Giraldo
Orozco

Dr. Antonio Martínez
Torteya

Dr. José María Celaya Padilla

Dr. Gamaliel Moreno Chávez

c.c.p. Interesado.

c.c.p. Responsable de la Maestría en Ciencias del Procesamiento de la Información.



SOMOS
ARTE, CIENCIA Y
DESARROLLO
CULTURAL

**COORDINACIÓN DE
INVESTIGACIÓN Y POSGRADO**

Carta de similitud núm.485 / IyP
Zacatecas, Zacatecas 16/noviembre/2023

Dr. Huizilopoztli Luna García
Responsable de la MCPI – UAZ
Presente

Estimado Dr. Huizilopoztli,

Después de saludarlo, sirva el presente oficio para notificar que el documento

"Detección del uso del casco en conductores de motocicleta, utilizando redes neuronales convolucionales"
de Jaime Mercado Reyna

Fue analizado con el software Copyleaks, con la intención de detectar similitudes; el resultado en cuestión fue

15.9 % de similitud

De acuerdo a lo anterior, el porcentaje se considera **ACEPTABLE** de acuerdo a los estándares internacionales.

Atentamente

"Somos Arte, Ciencia y Desarrollo Cultural"

Dr. Carlos Francisco Bautista Capetillo
Coordinador de Investigación y Posgrado
Universidad Autónoma de Zacatecas



SOMOS
ARTE, CIENCIA Y
DESARROLLO
CULTURAL



Zacatecas, Zac. 21 de noviembre de 2023

Carta de cesión de derechos

A QUIEN CORRESPONDA

El que suscribe, **C. Jaime Mercado Reyna**, alumno del Programa de **Maestría en Ciencias del Procesamiento de la Información**, con número de matrícula **42106548** y afiliado a la Unidad Académica de Ingeniería Eléctrica de la Universidad Autónoma de Zacatecas, manifiesta ser el autor intelectual del presente trabajo de tesis. Bajo la dirección de Dr. Huizilopoztli Luna García, cede los derechos del trabajo titulado “**Detección Del Uso Del Casco En Conductores De Motocicleta, Utilizando Redes Neuronales Convolucionales**” a la Universidad Autónoma de Zacatecas para su difusión con fines académicos y de investigación.

ATENTAMENTE

Jaime Mercado Reyna



SOMOS
ARTE, CIENCIA Y
DESARROLLO
CULTURAL



CONAHCYT
CONSEJO NACIONAL DE HUMANIDADES
CIENCIAS Y TECNOLOGÍAS

Agradecimiento especial

Quiero agradecer profunda y sinceramente al Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCYT) por su valioso apoyo económico brindado a mi persona a través de la Convocatoria Nacional (Tradicional) 2021 2023 en el periodo que cursé la Maestría en Ciencias del Procesamiento de la Información.

Agradecimiento

Quiero agradecer sinceramente a mi director de tesis, el **Dr. Huizilopoztli Luna García**, por su valioso apoyo que siempre me brindó desde el inicio hasta el fin de este proyecto, gracias por compartirme su conocimiento, ideas y consejos que en verdad resultaron útiles para mi desarrollo profesional y personal.

Gracias a mis asesores y profesores en algunas materias de la maestría, **Dr. José María Celaya padilla** y **Dr. Gamaliel Moreno Chávez**, gracias a mis asesores externos **Dr. William Joseph Giraldo Orozco** de la universidad del Quindío Colombia y **Dr. Antonio Martínez Torteya** de la universidad de Monterrey quienes de igual forma siempre me brindaron su apoyo, retroalimentación con el fin de que este proyecto fuera un verdadero aporte para la comunidad científica.

Gracias a mis compañeros de generación y docentes de la Maestría en ciencias del Procesamiento de la Información por transmitirme los conocimientos necesarios para poder concluir con esta etapa de mi formación profesional.

Gracias a todas las personas que laboran en la Unidad Académica de Ingeniería Eléctrica de la Benemérita Universidad Autónoma de Zacatecas por su apoyo en los diferentes procesos administrativos que fueron necesarios realizar en esta etapa.

Gracias a mi esposa, hermanos, padres, que siempre estuvieron al pendiente de mi bienestar, gracias por apoyarme económicamente cuando fue necesario, gracias por participar de este proyecto cuando así se los pedí.

Por último, agradezco al amigo y presidente municipal de Ojocaliente Lic. Daniel López Martínez por su apoyo y aliento.

Dedicatoria

Este trabajo quiero dedicarlo muy especialmente y de corazón a mi esposa **Carmina** y mi hijo **Jaime**, gracias por alentarme, por su cariño incondicional, por darme el espacio necesario para desarrollar este proyecto, ustedes son mi inspiración y motivo de vida, este logro también es suyo, los amo con toda mi alma.

No puedo dejar de lado a mis padres **Leticia Reyna Dávila** y **Jaime Mercado Perea**, aunque ya no vivamos debajo del mismo techo siempre están en mi corazón, agradezco infinitamente que me sigan apoyando, les dedico este éxito papás.

Resumen

Actualmente, la motocicleta es uno de los medios de transporte preferidos por las personas para movilizarse, principalmente en países donde el ingreso monetario es medio o bajo. Aunque la motocicleta tiene varias prestaciones que motivan su uso, también cuenta con una seguridad deficiente que pueda proteger al usuario, por lo que hoy en día existe una elevada tasa de muertes y lesiones graves en accidentes de tránsito donde se ven involucrados estos vehículos. Como se ha concluido en varios trabajos que consideran el tema de la seguridad en la motocicleta, el elemento protector de mayor eficacia con el que pueden contar los usuarios es el casco, el cual puede reducir hasta un 69% el riesgo de sufrir una lesión grave en la cabeza y un 42% la muerte. A la fecha existen distintas propuestas que buscan mejorar el uso del casco por parte de los motociclistas detectando este elemento, basándose en el uso de herramientas del aprendizaje automático. Se ha identificado que tales propuestas no aseguran que el usuario utilice el casco en el momento de la detección, por lo cual la corrección de la acción del uso del casco no se realiza en tiempo real, y por lo tanto el riesgo de sufrir la lesión o muerte no disminuye. Esta área de oportunidad deriva en el presente trabajo que tiene como principal objetivo el generar un modelo inteligente de detección del casco con una perspectiva de “prevención”, el cual a partir de ser entrenado con imágenes obtenidas desde una cámara montada en la motocicleta podrá vigilar que el usuario utilice el casco en todo el trayecto que realice. Como resultado de utilizar las redes neuronales convolucionales, la transferencia de aprendizaje y el nuevo enfoque del sistema, se ha producido un modelo de detección del uso del casco en conductores de motocicleta, el cual en su etapa de prueba pudo detectar correctamente el 97.24% de las imágenes dadas de personas con y sin casco. Esta idea innovadora se puede mejorar al robustecer los datos con los que se entrena y se prueba el modelo, utilizando nuevas arquitecturas de redes neuronales, entre otras opciones, pero esta primera aproximación es un buen punto de partida para trabajos futuros.

Abstract

Currently, motorcycles are one of the preferred means of transportation for people to get around, mainly in countries where the monetary income is medium or low. Although the motorcycle has several features that motivate its use, it also has a deficient safety that can protect the user, which is why today there is a high rate of deaths and serious injuries in traffic accidents involving these vehicles. As has been concluded in several works that consider the subject of motorcycle safety, the most effective protective element that users can count on is the helmet, which can reduce up to 69% the risk of suffering a serious head injury and 42% the risk of death. To date there are several proposals that seek to improve the use of helmets by motorcyclists by detecting this element, based on the use of machine learning tools. It has been identified that such proposals do not ensure that the user uses the helmet at the time of detection, so the correction of the helmet use action is not performed in real time, and therefore the risk of injury or death does not decrease. This area of opportunity leads to the present work, whose main objective is to generate an intelligent helmet detection model with a "prevention" perspective, which, after being trained with images obtained from a camera mounted on the motorcycle, will be able to monitor that the user uses the helmet throughout the entire route. As a result of using convolutional neural networks, transfer learning and the new system approach, a model for detecting helmet use in motorcycle drivers has been produced, which in its testing stage was able to correctly detect 97.24% of the given images of people with and without helmets. This innovative idea can be improved by robustening the data with which the model is trained and tested, using new neural network architectures, among other options, but this first approach is a good starting point for future work.

Contenido general

Agradecimiento especial.....	ii
Agradecimiento.....	iii
Dedicatoria.....	iv
Resumen.....	v
Abstract.....	vi
Contenido general.....	vii
Índice de Figuras.....	ix
Capítulo 1. Introducción.....	10
1.1 Antecedentes.....	10
1.2 Planteamiento del problema de investigación.....	12
1.3 Justificación del problema de investigación.....	15
1.4 Preguntas de investigación.....	16
1.5 Objetivo general.....	16
1.6 Objetivos específicos.....	16
1.7 Hipótesis.....	17
1.8 Estructura de la tesis.....	17
Capítulo 2. Marco Teórico.....	18
2.1 Seguridad Vial.....	19
2.1.1 Accidentes viales.....	21

2.1.2 Seguridad en la motocicleta.....	24
2.1.3 Leyes relacionadas a la motocicleta.....	27
2.1.4 Casco protector.....	29
2.2 Inteligencia Artificial.....	33
2.2.1 Aprendizaje Automático.....	34
2.3 Principales estudios relacionados	46
Capítulo 3. Método y propuesta de investigación	49
3.1 Método de investigación.....	49
3.2 Artículo, Etapa 2 de la propuesta de investigación.....	51
Capítulo 4. Conclusiones	70
Referencias.....	71
Anexos	83

Índice de Figuras

Figura 1. índice del marco teórico.....	18
Figura 2 Número de vehículos motorizados y tasa de muerte globalmente (OMS, 2018).....	22
Figura 3 Accidentes Viales anuales en México (OMS, 2018).	23
Figura 4 Colisiones con motocicletas en México (OMS, 2018).....	23
Figura 5 Distribución de las defunciones por tipo de persona usuaria, 2014-2019	24
Figura 6. Tipos de cascos (Motorcycle Legal Foundation, 2021).....	30
Figura 7. Puntos de impacto aproximados en cascos de motocicletas.(Khosroshahi et al., 2015).	31
Figura 8. El DL como subconjunto de ML, que a su vez es subconjunto de IA.(Madan & Madhavan, 2020).....	36
Figura 9. Estructura básica de una ANN.	37
Figura 10. Arquitectura de una CNN para el reconocimiento de dígitos escritos a mano (LeCun et al., 1998).....	38
Figura 11. Ejemplo de filtro de convolución.....	39
Figura 12. Ejemplo de paso 1 en figura de 7*7 con filtro de 3*3.	39
Figura 13. Función Sigmoide (Activation Functions: Sigmoid vs Tanh, 2023).	41
Figura 14. Función Tanh (Activation Functions: Sigmoid vs Tanh, 2023).....	41
Figura 15. Ejemplo Agrupación máxima con reducción de resolución. El ancho de la agrupación es de 3 unidades y un paso de 2 unidades.	43
Figura 16. Propuesta de investigación.....	49
Figura 17. Resultados esperados por etapa 1, 2 y 3.....	50

Capítulo 1. Introducción

En el presente capítulo, se describen antecedentes relacionados con el uso de la motocicleta como medio de transporte y el casco protector, enseguida se expone el planteamiento y justificación del problema de investigación, después se presentan las preguntas de investigación las cuales estarán relacionadas por el siguiente punto descrito en este apartado que es el objetivo general y objetivos específicos, además se enuncia la hipótesis y al final se presenta la estructura general del estudio.

1.1 Antecedentes

El uso de las motocicletas como medio de transporte ha ido incrementando en las últimas décadas a causa de la urbanización, la cual también ha creado una nueva demanda de movilidad, que en su mayor parte ha sido satisfecha por la industria del transporte privado individual, dentro de la cual las motocicletas destacan; para el año 2021 cerca del 30% de los vehículos en el mundo eran motocicletas (Cadavid & Salazar-Serna, 2021). Comparando los vehículos de cuatro ruedas (automóviles) con las motocicletas, estas últimas son un medio de transporte personal más asequible ya que necesitan menos recursos para su funcionamiento y manejo como lo son el combustible y el espacio, además que su costo de adquisición es hasta 10 veces más bajo que el de un vehículo (Jittrapirom et al., 2017), por lo que su uso se ha incrementado de manera exponencial. Otros aspectos positivos que propician el uso de estos vehículos de dos o tres ruedas es, que tienen la habilidad de conducirse sobre caminos deteriorados o en mal estado, en tráfico congestionado en zonas urbanas y además el tiempo de traslados en áreas urbanas es reducido comparándolo con el tiempo al usar un vehículo o transporte público (Abdi et al., 2021).

Particularmente, en países de ingresos medio-bajo (LMIC, por sus siglas en inglés) los principales propósitos del uso de las motocicletas son: como medio de transporte privado y como herramienta de trabajo para el desarrollo de nuevas actividades generadoras de ingresos que han surgido en los últimos años como lo es la entrega de comida a domicilio. Cabe señalar que, aunque la mayor parte del crecimiento se ha producido en Asia, las motocicletas se han vuelto cada vez más importantes en los países de América Latina (Hagen et al., 2016).

De acuerdo con los últimos datos actualizados por el Instituto Nacional de Estadística y Geografía (INEGI), indican que del año 2011 al 2021 la cantidad de motocicletas registradas en

circulación en México paso de ser de sólo 1,313,122 unidades a 5,939,262 unidades (INEGI, 2023), y para ese mismo año el Mercado de Motocicletas en México superó al brasileño convirtiéndose en el más grande de toda América Latina (MotorCycles Data, 2022).

Debido a este aumento en el uso de las motocicletas como medio de transporte se han llevado a cabo estudios para entender cómo se está generando tal crecimiento y que impacto está teniendo en la sociedad en temas de salud, infraestructura vial, etc. En cuanto a la cuestión de salud, el impacto ha sido negativo si hablamos de la cantidad de muertes resultantes a partir de accidentes de tráfico donde se ven involucradas las motocicletas. A nivel mundial, los accidentes de tránsito causan más de 1.35 millones de muertes, y específicamente el 28% de estas muertes corresponden solamente a usuarios de vehículos de 2-3 ruedas (OMS, 2018), este alto porcentaje se da ya que las motocicletas no cuentan con alguna estructura que pueda proteger al conductor y sus acompañantes al momento de sufrir un percance (Cheng et al., 2015).

Ahora, el identificar los distintos factores de riesgo que derivan en estas lesiones y muertes en accidentes viales es un punto de vital importancia para mejorar la seguridad en la motocicleta. Tales factores pueden estar asociados con el entorno de la vía, el vehículo, el usuario de la vía o el nivel de respuesta posterior a la colisión (OMS, 2022). Entre los factores asociados al usuario resalta la falta del uso del casco, el cual es el elemento más importante que influye en la disminución del riesgo de lesiones en la cabeza y muertes asociadas a los accidentes de tránsito. En la actualidad, existen intervenciones efectivas probadas que pueden mejorar la seguridad en las motocicletas, aunque el uso correcto del casco sigue siendo la forma más efectiva dado que disminuyen significativamente la fuerza del impacto de un choque y así previenen lesiones craneofaciales graves (OMS, 2022). “El uso correcto del casco puede dar lugar a reducciones del 42% en el riesgo de traumatismo mortales y del 69% en el riesgo de traumatismos craneales” (OMS, 2018).

En cuanto al tema de normativas, “el hecho de la sola promulgación de leyes obligatorias sobre el uso del casco, no conduce a mejorar el comportamiento entre los motociclistas” (Mahdavi Sharif et al., 2022), a nivel mundial 94% de los países cuentan con una ley nacional que obliga a los motociclistas a usar el casco, pero en la mayoría de los casos estas leyes tienden a tener lagunas que afectan su efectividad de manera negativa (Araujo et al., 2017). Por otro lado, la OMS, (2021) expone que es necesario aplicar normas legislativas con un objetivo distinto, el de armonizar el diseño y la tecnología de vehículos, con el fin de garantizar una uniformidad y nivel aceptable de seguridad vial en todo el mundo.

Tomando en cuenta los datos de accidentes viales y uso del casco en los motociclistas, se afirma que deben seguirse las acciones recomendadas por parte de la OMS en el punto de mejorar la seguridad en los vehículos, tales acciones deben enfocarse en que el diseño del vehículo integre características ya sea para evitar choques (seguridad activa) o para reducir el riesgo de lesiones para los ocupantes y otros usuarios de la vía cuando se produce un percance (seguridad pasiva) (OMS, 2021).

La incorporación de Sistemas de Transporte Inteligentes o ITS por sus siglas en inglés (Intelligent Transportation Systems) los cuales se enfocan en la integración de los vehículos, sus usuarios y las vías de traslado con el fin de mejorar la seguridad son intervenciones que han incrementado la seguridad en la motocicleta, el Sistema Antibloqueo de Frenos (ABS por sus siglas en inglés) y las luces de circulación diurna son ejemplos de esto (Flanigan et al., 2018). Como se comenta en este último trabajo, aunque la investigación acerca de los beneficios de la incorporación de los ITS en la seguridad de la motocicleta es relativamente escasa, esto no significa que no exista un potencial de mejora en la conjunción de estos sistemas y la motocicleta; la colaboración de todos los sectores de la industria de la motocicleta se debe expandir para seguir mejorando la seguridad y la experiencia de viaje.

Por otra parte, los gobiernos de diferentes países enfrentan y tratan de mitigar el problema de las muertes en accidentes de tráfico relacionadas con el uso de las motocicletas implementando sistemas con ciertas características favorables como lo son la flexibilidad y los costos bajos de aplicación y mantenimiento, a partir de esto, se han desarrollado varios ITS que utilizando diferentes tecnologías como radares, sensores de sonido u ópticos, entre otros pueden detectar a la motocicleta y algunos el uso del casco en los motociclistas para así sancionar a los infractores de las normativas viales y generarles una infracción (Ambak et al., 2009).

1.2 Planteamiento del problema de investigación

Desde el punto de vista social, el problema es la elevada tasa de mortalidad de los motociclistas a causa de un accidente de tránsito, se estima que los motociclistas tienen una probabilidad 27 veces mayor de morir a comparación con los ocupantes de automóviles (Venkatraman et al., 2020). Este daño potencial se ve incrementado por varios factores de riesgo, tales como lo son el error del conductor, consumo de alcohol o drogas, el exceso de velocidad y el diseño del vehículo (Akbari et al., 2021).

A nivel nacional en México, en el periodo del 2014 al 2019, las muertes de motociclistas se duplicaron y la tasa de mortalidad aumentó un 36%, este incremento alarmante estaba por encima de lo proyectado por las autoridades mexicanas (STCONAPRA, 2022). Particularmente para el año 2020 en el país, los usuarios de motocicletas que se encontraban entre los grupos de edad de adolescentes y personas adultas jóvenes eran los más propensos a sufrir una lesión y requerir hospitalización. Otro dato alarmante es que el 71.6% de todos los egresos hospitalarios de estos grupos etarios causados por un accidente vial correspondían solamente a usuarios de motocicleta, por lo que se vuelve importante entender el cómo se están utilizando las motocicletas por estos jóvenes, para así desarrollar medidas preventivas y aplicarlas principalmente en LMIC donde se concentra aproximadamente el 90% de las muertes en accidentes de tráfico (STCONAPRA, 2023) (Rahim Khan et al., 2022).

Entre las principales causas de muerte, lesiones graves y discapacidad de los usuarios de motocicletas están las lesiones en cabeza y cuello, las cuales para el año 2010 ya eran causantes del 50% de las fatalidades registradas (MacLeod et al., 2010), aunque el traumatismo en las extremidades bajas es la lesión más común en los motociclistas las lesiones en la cabeza son las más graves (Houkpe Dos Santos et al., 2021). Diferentes estudios muestran que los motociclistas que estaban usando el casco al momento de sufrir un accidente vial tuvieron menos lesiones en la cabeza y el cuello, y por lo tanto los costos de hospitalización y recursos necesarios para su recuperación fueron menores (Kim et al., 2015) (Sisimwo & Onchiri, 2018) (Ali et al., 2021).

En los países clasificados como LMIC, más del 50% de los motociclistas no usan algún tipo de casco protector al conducir (Tabary et al., 2021). Muchos factores están involucrados con este problema, entre los clasificados como factores personales se pueden mencionar la incomodidad térmica y peso del casco, efectos visuales y auditivos que causan su uso, y por la parte de los factores contextuales están la hora del día, zona de circulación, condiciones climatológicas, etc. Aunque cabe mencionar que tales factores están relacionados con el contexto geográfico y cultural de cada área de estudio mencionada en la literatura (Ledesma, 2008) (Tsui et al., 2013) (Nacional De Lanús et al., 2016).

Ahora, es importante entender cómo es que los sistemas para la detección del casco han evolucionado. De manera tradicional, y con el fin de incentivar el uso del casco, la detección de este elemento de seguridad la realiza el personal policiaco responsable de la seguridad vial, estos elementos checan de manera visual en puntos de control el uso correcto del casco y consecuentemente realiza alguna acción de acuerdo a las normas que se rigen en el lugar; pero

este sistema tiene la limitante de depender de la cantidad de elementos de seguridad vial disponibles capacitados para realizar tal tarea, y además tienen la deficiencia que pueden ser vulnerados al momento que un conductor infractor tome vías alternas evitando así el punto de control (Jia et al., 2021) (B.-S. Wang et al., 2023). Tomando esto en cuenta, y como se mencionó anteriormente, surgieron algunos ITS que ayudan en la tarea de detección al monitorear el tráfico en busca de infractores a partir de cámaras instaladas en diferentes puntos de la vía, estos sistemas siguen siendo sistemas pasivos, ya que requieren la asistencia de una persona para su óptimo funcionamiento, por lo que su eficiencia disminuye en periodos de operación largos (Singh et al., 2022). La automatización de estas propuestas utilizando diferentes herramientas de aprendizaje automático ha ayudado al mejoramiento del monitoreo y disminución de los recursos humanos necesarios para su funcionamiento, pero, estas propuestas siguen teniendo un punto vulnerable, son sistemas fijos, es decir no monitorean todo el trayecto del motociclista, y además, ya que estos sistemas deben instalarse en la mayoría de las vialidades, puede ser una opción no viable en términos económicos, además de depender de una conectividad suficientemente buena para que su efectividad no se vea afectada (Goyal et al., 2022).

En la última década se han desarrollado una gran variedad de proyectos que tienen como objetivo el mejorar la seguridad de la motocicleta tratando de que los usuarios porten el casco durante todo el recorrido que realicen. Por ejemplo, el presentado por (Mohd Rasli et al., 2013), donde una resistencia de detección de fuerza monitorea la presencia de la cabeza del conductor; este sistema utiliza transmisores, receptores y un microcontrolador para poder realizar la tarea de detección del uso correcto del casco. Otros trabajos relacionados más recientes usan herramientas de la Inteligencia Artificial en específico del Aprendizaje Profundo para la detección de motociclistas en videos de tráfico urbano; esto con el fin de apoyar a los responsables de seguridad vial en la tarea de detectar a infractores del reglamento en cuanto al uso de casco (Rohith et al., 2019) (Jia et al., 2021) (Cui et al., 2023) (Aboah et al., 2023); existen más propuestas que buscan detectar el uso del casco utilizando herramientas del aprendizaje automático, pero en general, se puede mencionar que la mayoría tienen un enfoque de generación de un sistema correctivo, donde el objetivo de la implementación de las propuestas es la generación de multas de manera automática.

1.3 Justificación del problema de investigación

Se pueden prevenir los traumatismos por colisiones en el tránsito con intervenciones eficaces que incluyan el diseño de infraestructuras más seguras, mejorando las características de seguridad de los vehículos, mejorando la atención posterior al accidente para las víctimas de los accidentes, estableciendo y haciendo cumplir las leyes relacionadas a la seguridad vial, etc. (OMS, 2022a). En cuanto al uso del casco ya se han establecido leyes que obligan a las personas a usar cascos si están conduciendo una motocicleta como la NOM-206-SCFI/SSA2-2018 en México (DOF - Diario Oficial de La Federación, 2018), se han generado propuestas basadas en herramientas de la Inteligencia Artificial o I.A. para hacer cumplir estas leyes como el de (Waris et al., 2022), otros trabajos sugieren nuevos diseños en la infraestructura vial, un ejemplo es la creación de una línea o carril de uso exclusivo para motocicletas en el país de Malaysia (Saini et al., 2022), se han incorporado en algunas motocicletas ciertos Sistemas de Transporte Inteligente o ITS (Flanigan et al., 2018), pero el mejorar las características de seguridad mismas de la motocicleta con el uso de herramientas de I.A. es un área que la comunidad científica no ha profundizado, ya que esto se ha dejado sólo como un tema de importancia para los fabricantes de las motocicletas.

Como se comentó en el apartado anterior, en los últimos años se han desarrollado trabajos con el fin de hacer cumplir las leyes de tránsito que se relacionan con el uso del casco por parte de los motociclistas, esto a partir de la extracción de imágenes de vídeos de tráfico urbano y su consecuente procesamiento en un sistema inteligente. Aunque, la limitante de este tipo de propuestas es que su implementación está ligada solamente a las instituciones de gobierno quienes serán las encargadas de monitorear y controlar estos sistemas y por lo tanto tales instituciones deben cubrir con todo el gasto generado, a parte que, aunque ya sean Sistemas Inteligentes, son fijos, y por lo tanto tienen dependencia de la zona de instalación por lo que no pueden monitorear constantemente a los motociclistas en todo el trayecto, y de igual forma que los puntos de control son vulnerables al tomar vías alternas. Otro aspecto que limita sus resultados es que al estar pensados para que interactúen con otros elementos como bases de datos de placas del parque vehicular registrado, la detección en tiempo real que realizan se vuelve inefectiva. La generación de la multa no previene una lesión o muerte en el momento cuando el motociclista fue detectado sin casco. “Vivimos en un mundo donde las reglas de tránsito no tienen importancia para las personas y son violadas regularmente. Además, que es parte de la naturaleza humana el resistirse a lo que se le impone”(Vashisth et al., 2017).

1.4 Preguntas de investigación

En la presente investigación se plantean cuatro preguntas a partir de la revisión crítica de literatura realizada.

1. ¿De qué manera del casco afecta la seguridad de los motociclistas al momento de estar conduciendo?
2. ¿Qué propuestas hasta la fecha tienen como objetivo el incentivar el uso del casco en los conductores de motocicleta?
3. ¿Con qué herramientas de aprendizaje automático se puede generar un modelo inteligente que pueda detectar si una persona está utilizando un casco al momento de conducir una motocicleta?
4. ¿Con que métricas se puede analizar los resultados del modelo de aprendizaje automático producido?

1.5 Objetivo general

El objetivo general que guía el presente trabajo es el siguiente:

Desarrollar un modelo de aprendizaje automático utilizando redes neuronales convolucionales, que pueda detectar el uso del casco en los motociclistas con una precisión mayor al 95 por ciento.

1.6 Objetivos específicos

1. Analizar el estado del arte en la literatura respecto al “uso del casco en conductores de motocicleta”.
2. Identificar herramientas de aprendizaje automático que se pueden usar para garantizar que el motociclista utilice el casco protector.
3. Crear una base de datos de imágenes equilibrada de personas con y sin casco.
4. Generar el modelo de aprendizaje automático utilizando el reentrenamiento y transferencia de aprendizaje de la red neuronal convolucional elegida.
5. Analizar los resultados obtenidos en la prueba del modelo y plantear el trabajo futuro.

1.7 Hipótesis

La Hipótesis de investigación del presente trabajo según (Hernández Sampieri, 2017), se cataloga como una hipótesis descriptiva ya que pronostica una cifra y es la siguiente:

“El modelo propuesto clasificará las imágenes de personas que usan y no usan casco protector, con una precisión mayor al 95%”.

Es indispensable definir conceptual y operacionalmente las variables involucradas en la hipótesis de investigación, para que en general el significado de los términos o variables incluidas en la hipótesis sea claro y así evaluar de mejor manera los resultados arrojados por el proyecto de investigación (Hernández Sampieri, 2017). Enseguida se presenta las definiciones conceptuales y operacionales de las variables “imagen” y “precisión”.

Definición conceptual de la variable dependiente “imagen”:

“Figura, representación, semejanza y apariencia de algo” (*Imagen / Diccionario de La Lengua Española (2001) / RAE - ASALE, 2001*).

Definición operacional de la variable “imagen”:

Filmación de videos con una cámara (GoPro HERO5Session). Extraer los fotogramas de los videos capturados con un programa ejecutable.

Definición conceptual de la variable “precisión”:

“La métrica de precisión es utilizada para poder saber qué porcentaje de valores que se han clasificado como positivos son realmente positivos. $\text{Precision} = \text{TP} / (\text{TP} + \text{FP})$ ” (Díaz, 2020).

Definición operacional de la variable “precisión”:

Producir la matriz de confusión del modelo y calcular la precisión mediante la formula Verdaderos Positivos / Verdaderos Positivos + Falsos Positivos.

1.8 Estructura de la tesis

El presente trabajo sigue la estructura indicada a continuación:

En el capítulo dos se presenta el marco teórico con la descripción de las teorías base de la investigación que orientaron el desarrollo del estudio, enseguida se presenta el apartado correspondiente a los principales estudios relacionados, que se vinculan directamente con el

problema de investigación. Enseguida, se presentan los apartados que detallan las contribuciones y limitaciones de los estudios previos y el de comparación entre la propuesta de investigación y los trabajos relacionados.

En el capítulo 3 se describe la metodología empleada en la investigación y el proceso de implementación de las redes neuronales convolucionales para la detección del uso del casco en los conductores de motocicleta (Artículo publicado en revista indexada).

En el capítulo 4 se finaliza el trabajo de investigación con las conclusiones, donde se detallan los objetivos alcanzados, la conclusión acerca de la hipótesis y las contribuciones de la investigación.

Capítulo 2. Marco Teórico

En este capítulo la parte teórica de la investigación es presentada. Al comienzo se encuentra el índice con las teorías base: Seguridad Vial e Inteligencia Artificial, con sus consecuentes apartados que tienen relación directa con el problema de investigación. Estos temas y subtemas tienen como objetivo el “dar orden al conocimiento sobre un fenómeno o realidad” (Hernández Sampieri, 2017), ver Figura 1.

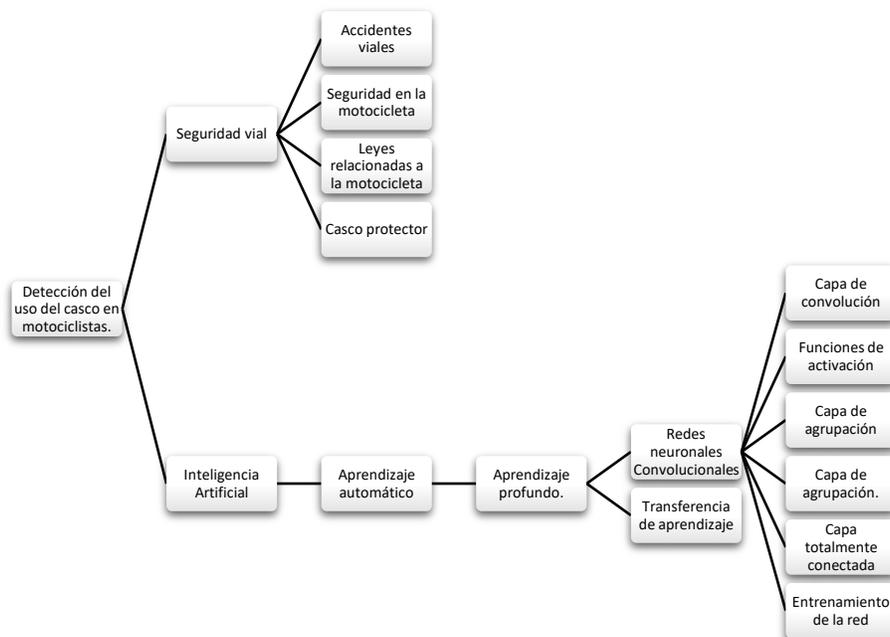


Figura 1. índice del marco teórico.

2.1 Seguridad Vial

Con el crecimiento de las ciudades, las carreteras y la aparición de los automotores fue necesaria la regulación en torno a estas formas y estilos de transportación. La seguridad vial se convirtió en una variable indispensable para contar con un tránsito más confiable y estable por la vía pública. (*Gobierno de México, 2022*)

El mejorar la seguridad vial es un desafío importante para la sociedad. “La falta de conciencia sobre la seguridad vial por parte de los conductores, el incumplimiento normativo y la aplicación limitada de la legislación se consideran las principales barreras para reducir las muertes por accidentes de tránsito” (*United Nations, 2018*).

La Seguridad Vial se compone tomando partes de distintos temas como la salud, tecnología y legislación, por lo cual, se puede estudiar, evaluar y mejorar desde diferentes perspectivas.

En cuanto al tema de Salud, generalmente se detalla información acerca de la mortalidad en accidentes viales, sus tasas de mortalidad por personas usuarias y respectivas proyecciones. Cabe detallar que las personas usuarias etiquetadas como “usuarios vulnerables de la vía pública”, son los que corren mayor riesgo en tráfico, ya que no están protegidos por una estructura externa que pueda absorber el impacto de un choque en la vía; los peatones, ciclistas y motociclistas son considerados usuarios vulnerables de la vía (*Vulnerable Road Users, VRUs* por sus siglas en inglés) (*Yannis et al., 2020*)

En relación al tema de la Tecnología como parte de la Seguridad Vial, su implementación busca mejorar la seguridad, salvar vidas, reducir costos y ser amigable con el medio ambiente (*Tonhauser & Ristvej, 2021*). Entre los ejemplos son los asistentes electrónicos que se pueden encontrar en varios vehículos modernos, asistentes que pueden mantener el vehículo en el camino, el frenado autónomo para proteger a los peatones delante del vehículo o a los pasajeros dentro del mismo o el monitoreo del comportamiento del conductor. Los Sistemas de Transporte Inteligentes (*Intelligent Transportation Systems, ITS*), son otro resultado de la implementación de la tecnología en la Seguridad Vial. “El término ITS se refiere a aplicaciones integradas, empleando combinaciones de tecnologías de información, comunicaciones, computación, sensores y control, cuyo objetivo es mejorar la seguridad en el transporte y la movilidad” (*Ambak et al., 2009*). Como se mencionan por (*Tonhauser & Ristvej, 2021*) , mejorar la seguridad es un proceso que nunca

terminará y, por lo general, es a largo plazo. Implementar nuevas tecnologías y obtener datos relevantes de su impacto es un proceso que puede llevar años.

En cuanto a la Legislación, “es de vital importancia que todos los países revisen y mejoren sus políticas y estrategias de seguridad vial, basándose en una comprensión objetiva de su situación (Toriumi et al., 2022). A nivel global se realizan diferentes estudios, reportes y planes con el fin de mejorar la Seguridad Vial, también se llevan a cabo diferentes acciones como la creación de bases de datos, que “reúnen información validada acerca de la Seguridad Vial de distintos países con lo cual se proporciona una base empírica para comparaciones internacionales y políticas más efectivas” (IRTAD, 2019). Un caso son las bases de datos creadas por el Grupo Internacional de Datos y Análisis de Seguridad del Tráfico (International Traffic Safety Data and Analysis Group, IRTAD por sus siglas en inglés), el cual es el grupo de trabajo permanente para la seguridad vial del ITF. Estas bases de datos incluyen información sobre límites de velocidad nacionales, límites de contenido de alcohol en sangre (BAC), normas de uso del casco, normas de retención infantil, reglamentos de uso del teléfono móvil y reglamentos relacionados con la conducción bajo la influencia de las drogas. “Esta información puede ayudar a delinear las reglas de tránsito que los conductores deben seguir en diferentes países”(Toriumi et al., 2022). De igual manera los reportes del estatus de la Seguridad Vial aportan información muy importante para evaluar que se ha hecho bien y que oportunidades de mejora existen entorno a este tema. Por ejemplo, el último llevado a cabo por la Organización Mundial de la Salud fue el del año 2018, en el cual “muestra que se han logrado avances en áreas importantes como la legislación, los estándares de los vehículos y mejorar el acceso a la atención post-colisión, pero, sin embargo, este progreso no se ha producido a un ritmo suficientemente rápido para compensar el aumento de la población y la rápida motorización del transporte que tiene lugar en muchas partes del mundo” (OMS, 2018).

Los Planes de Acción también son de vital importancia para seguir con un desarrollo enfocado en el progreso de los sistemas que se involucran en el tema mencionado. La OMS es un organismo preocupado por la Seguridad Vial, por eso ha redactado su segundo Plan de Acción Global por diez años 2021-2030. Estos Planes de Acción “están dirigidos a los principales responsables de la formulación de políticas y debe servir como modelo para el desarrollo de planes y objetivos nacionales y locales” (OMS, 2021). En este el último Plan Global “pide a los gobiernos y partes interesadas que prioricen e implementen un enfoque integrado de Sistema Seguro que posicione de lleno a la seguridad vial como un impulsor clave de desarrollo sostenible” (OMS, 2021). En otra parte de este plan se proponen recomendaciones que pueden usarse para informar el

desarrollo de planes de acción nacionales de seguridad vial que se adaptan a los contextos locales, los recursos disponibles y la capacidad. Existen recomendaciones para garantizar la seguridad de los vehículos, como lo es el requerir estándares de seguridad armonizados de alta calidad en vehículos nuevos y usados, cinturones de seguridad, sistemas de retención infantil y cascos de motocicleta.

En cuanto a las autoridades gubernamentales en México, de igual manera que en muchos países del mundo informan mediante trabajos publicados la situación de la Seguridad Vial en su territorio, por ejemplo, a nivel Federal en México, se han hecho una serie de trabajos que el Secretariado Técnico del Consejo Nacional para la Prevención de Accidentes (STCONAPRA) de la Secretaría de Salud ha publicado en la materia. El décimo trabajo fue publicado en Julio del 2022 y contiene un diagnóstico de la situación de la seguridad vial en México, resaltando las deficiencias y los puntos críticos, a fin de brindar herramientas a las autoridades nacionales, estatales y municipales, y a la población en general para así concretar acciones en favor de la seguridad vial, asimismo, promueve intervenciones que sitúan a las personas en el centro de las políticas públicas y no a los automóviles, como ha sucedido en las últimas décadas, con base en buenas prácticas nacionales e internacionales y en evidencia científica (STCONAPRA, 2022).

2.1.1 Accidentes viales

“La Seguridad Vial es uno de los objetivos globales más cruciales. En los Objetivos de Desarrollo Sostenible (ODS) de las Naciones Unidas (ONU), la meta 3.6 tiene como objetivo reducir a la mitad el número de muertes y lesiones en el mundo por accidentes de tráfico accidentes” (Toriumi et al., 2022); esta meta está incluida en el Objetivo 3 que busca garantizar una vida sana y promover el bienestar para todos en todas las edades (Department of Economic and Social Affairs ONU, 2022). En agosto de 2020, la Asamblea General de las Naciones Unidas aprobó la proclamación del periodo 2021-2030 como la Segunda Década de Acción para la Seguridad Vial, acorde con la Agenda 2030 para el Desarrollo Sostenible, reiterando el objetivo de reducir en un 50 % el número de muertes por lesiones causadas por el tránsito para 2030 (STCONAPRA, 2022). Más del 90% de las defunciones causadas por accidentes de tránsito se producen en los países de ingresos bajos y medianos. Desde una edad temprana, los hombres tienen más probabilidades que las mujeres de verse involucrados en colisiones causadas por el tránsito. El 73% de estas defunciones corresponden a varones menores a 25 años.

Algunas cifras referentes a las muertes causadas por traumatismos en accidentes de tránsito presentadas en el más reciente Reporte del Estatus Global de Seguridad Vial son las siguientes (OMS, 2018):

- Son las principales causas de muerte de niños y adultos jóvenes (5-29 años).
- Es la octava principal causa de muerte en personas de cualquier edad.
- Cada año mueren aproximadamente 1.35 millones de personas en accidentes de tráfico.
- Más de la mitad de estas muertes corresponden a los Usuarios Vulnerables de la Vía (VRUs), motociclistas, peatones y ciclistas.
- La cifra de muertes causadas por un accidente vial es 3 veces menor en países de alto desarrollo comparado con la cifra de países de bajo desarrollo.

En la Figura 2 se muestra el número de vehículos registrados en el mundo y la tasa de muertes por accidentes de tránsito por cada 100.000 vehículos a nivel global del 2000 al 2016 por año, en la cual se ve una disminución en la tasa de mortalidad de alrededor del 50% y un aumento en la cantidad de vehículos en este periodo, con lo que se puede sugerir que si se han disminuido de cierta forma los aspectos negativos de los vehículos en general (OMS, 2018).

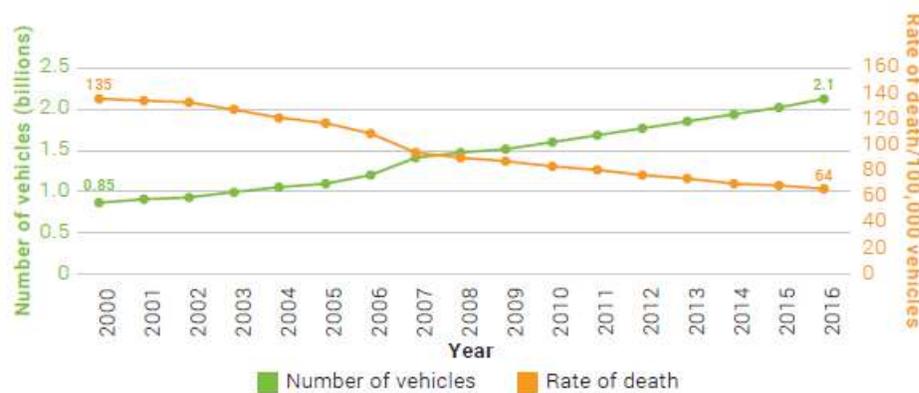


Figura 2 Número de vehículos motorizados y tasa de muerte globalmente (OMS, 2018).

A nivel nacional la cantidad de accidentes viales en el periodo del año del 2010 al 2021 se vio disminuida de 816,945 a 638,352 (INEGI, 2021), ver *Figura 3*.



Figura 3 Accidentes Viales anuales en México (OMS, 2018).

Aunque hay una disminución en la cantidad general de accidentes viales, las colisiones con motocicletas no siguen la misma evolución, las cuales se han duplicado en este periodo, ver Figura 4.



Figura 4 Colisiones con motocicletas en México (OMS, 2018).

La Distribución de las defunciones por tipo de persona usuaria en México, ver Figura 5, para el periodo 2014-2019 muestra que dos de cada tres defunciones corresponden a los Usuarios Vulnerables de la Vía (VRU's por sus siglas en inglés) (STCONAPRA, 2022).

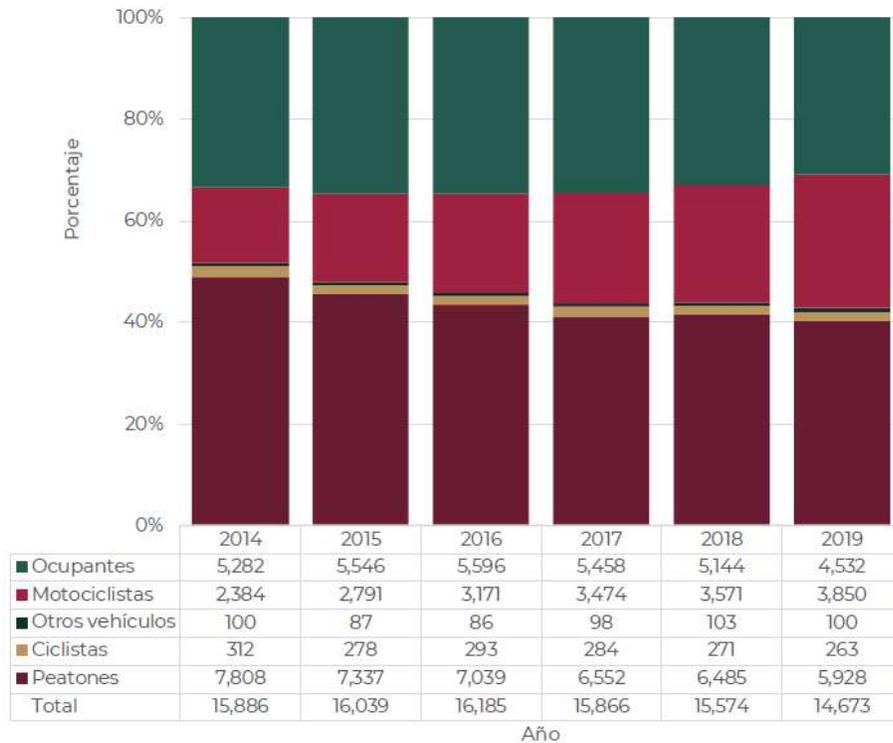


Figura 5 Distribución de las defunciones por tipo de persona usuaria, 2014-2019

Nota: Adaptado de Distribución de las defunciones por tipo de persona usuaria, 2014-2019, de STCONAPRA, 2022, de Informe sobre la Situación de la Seguridad Vial México 2020.

Al analizar la figura anterior se puede ver que el porcentaje correspondientes a los motociclistas paso de ser sólo el 15% del total de muertes en 2014 al 30.8% para el 2019.

2.1.2 Seguridad en la motocicleta.

El manejo de una motocicleta es inherentemente más difícil que el de un vehículo de pasajeros, puesto que requiere más habilidad física y fuerza. Aunque tienen esta desventaja “el uso de motocicletas está aumentando a nivel mundial, especialmente en los países de ingresos medianos y bajos; esto se debe a su menor costo, mejor ahorro de combustible y tamaño compacto conveniente para zonas congestionadas” (Yousif et al., 2020). De igual manera que el uso de las motocicletas incrementa, “el daño potencial asociado con cualquier accidente de tránsito suele ser mayor para los motociclistas y sus pasajeros, ya que no están protegidos por la estructura del vehículo” (Cheng et al., 2015).

A pesar de las barreras mencionadas en United Nations (2018), en cuanto a la mejora de la

seguridad vial mencionadas anteriormente, se siguen explorando diferentes estrategias de solución para mitigar la cantidad de accidentes viales donde se ven involucradas las motocicletas; tales estrategias “se pueden clasificar mayormente en tres partes, mejorar: el comportamiento de conducción, la infraestructura vial y las tecnologías de los vehículos” (Saini et al., 2022).

Las medidas basadas en la educación y la formación vial únicamente son efectivas si se utilizan como apoyo a otro tipo de medidas, y su efectividad depende mucho de la divulgación que se le dé a la misma (Novoa et al., 2009). En el estudio de (Petridou & Moustaki, 2000), se comprobó que el comportamiento humano es responsable del 95% de los accidentes de tránsito. En particular, la mayoría de los accidentes de motocicleta se deben a este tipo de errores (Yousif et al., 2020). “El comportamiento de los motociclistas se puede mejorar mediante la educación a través de campañas de seguridad y la retroalimentación de los conductores sobre su conducción” (Saini et al., 2022). No es raro ver a un motociclista conduciendo a altas velocidades, adelantando con más frecuencia y entrando en espacios más pequeños en el tráfico; en pocas palabras, generalmente son muy arriesgados en su manera de conducir. “La provisión de conocimientos y práctica de manejo se ha considerado la principal solución para la prevención de accidentes. La falta de experiencia se aborda principalmente de manera formal a través de programas de licencias, capacitación y educación para motociclistas”(Chou et al., 2022). El aumentar la conciencia de otros usuarios de la vía sobre los motociclistas, aumentando la visibilidad de los mismos y educando a los conductores sobre la importancia de compartir la carretera con estos vehículos de 2-3 ruedas es otra manera de buscar mejorar la seguridad de la motocicleta (Venkatraman et al., 2020).

En la parte de infraestructura vial, existe la necesidad de profundizar la comprensión de las relaciones entre las diferentes infraestructuras viales y el tráfico, sus influencias en la concentración de accidentes de motocicletas y lesiones en las redes viales con el fin de construir medidas efectivas de prevención para este tipo de choques. Diferentes estudios han sugerido que la infraestructura vial incluido el diseño de vías geométricas y la disposición vial, juegan un papel importante en la determinación del riesgo de accidentes de tránsito. (Francis et al., 2021).

La creación de una línea o carril de uso exclusivo para motocicletas (Exclusive MotorCycle Lane, EMCL), es una de varias acciones con las cuales se busca reducir los conflictos con otros tipos de vehículos que circulan en la vía. Aunque todavía no se han considerado estándares para el diseño geométrico de tales líneas, ya se han construido algunas de estas EMCL en Malaysia basadas en la guía ATJ 35/2018, las cuales han reducido con efectividad la cantidad de accidentes donde se

ven involucradas las motocicletas (Saini et al., 2022). “Muchos factores ambientales también pueden afectar la seguridad de las motocicletas. Las superficies y marcas resbaladizas de la carretera, las irregularidades y escombros de la superficie, los arcenes sin pavimentar y las barreras implacables de la carretera pueden ser peligrosos”(Venkatraman et al., 2020). Existen diferentes estudios desarrollados en la última década que de igual manera tratan de mejorar la seguridad del uso de la motocicleta, esto lo hacen al proponer e implementar sistemas para monitorear el uso del casco protector en los motociclistas a partir de cámaras de circuito cerrado (Closed-circuit television, CCTV) instaladas en la infraestructura vial.

Otras estrategias para mejorar la seguridad tienen que ver con el tema de introducir nueva tecnología como parte de la misma motocicleta. El desarrollo de ITS basados en información, son tecnologías de comunicación que buscan mitigar la congestión del tráfico, mejorar la seguridad y mejorar la calidad del medio ambiente; estos ITS pueden proporcionar a los vehículos diferentes tipos y niveles de "inteligencia" para complementar al conductor (Ambak et al., 2009). La mayoría de los ITS ya existentes han sido desarrollados para los vehículos de pasajeros, a pesar de esto, la incorporación de estos sistemas como parte de la motocicleta han traído resultados favorables. Por ejemplo, en el estudio de (Teoh, 2011), encontraron que las motocicletas con frenos antibloqueo (Antilock Braking Systems, ABS por sus siglas en inglés), tenían una menor participación en choques fatales que las motocicletas sin frenos de este tipo. En este sistema lo que hace el ABS es controlar la velocidad de las ruedas al reducir la presión de los frenos cuando detecta un bloqueo inminente de las ruedas, permitiendo a los motociclistas aplicar los frenos por completo en caso de emergencia sin temor a que las ruedas se bloqueen. Según (Ambak et al., 2009) los ITS creados para autos, que pueden favorecer a la mejora de la seguridad en la motocicleta son los siguientes: sistema avanzado de asistencia al conductor, adaptación inteligente de la velocidad, sistema de monitoreo del conductor, sistema de advertencia y prevención de colisiones, sistema de advertencia de mantenimiento y cambio de carril, sistema de mejora de la visibilidad y el sistema de recordatorio del cinturón de seguridad. Tales sistemas han sido discutidos y analizados en su trabajo en términos de adaptabilidad y problemas propios de la seguridad en la motocicleta. Sin embargo, también se comenta que existe la necesidad de desarrollar estándares para el diseño de tecnologías ITS para motocicletas, al igual que para el diseño de tecnologías ITS para otros vehículos. Otra estrategia que tiene el mismo objetivo que las anteriores, es la relacionada a la detección del alcohol en los conductores, con el fin de usar dispositivos de bloqueo de encendido. Aunque es factible implementar estos sistemas de bloqueo en las motocicletas, existen problemas de responsabilidad y seguridad asociados principalmente

con las nuevas pruebas que deben tenerse en cuenta (Venkatraman et al., 2020).

2.1.3 Leyes relacionadas a la motocicleta

Los países deben implementar medidas efectivas que se adapten a sus necesidades con el objeto de reglamentar la Ley de Transporte, Tránsito y Vialidad, para el debido cumplimiento de las disposiciones en materia de Tránsito y Seguridad Vial.

Según (Venkatraman et al., 2020), las Leyes universales para el uso de cascos de motocicleta, han demostrado ser efectivas por varias evaluaciones de alta calidad con resultados consistentes. Aunque su aplicación no ha sido igualmente satisfactoria. En 2018, en Estados Unidos de América, el uso de cascos alcanzó el valor del 83 % en estados con leyes universales sobre cascos que cubren a todos los motociclistas, y del 57 % en los estados sin leyes o con leyes de cobertura parcial.

En el país de México, se publicó en el Diario Oficial de la Federación, el decreto por el que se expide la Ley General de Movilidad y Seguridad Vial, en fecha 17 de mayo de 2022. Tal ley en su capítulo V “Planeación y Programación de la Movilidad y la Seguridad Vial”, sección tercera “De los Instrumentos de Política Pública de Movilidad y Seguridad Vial del Tránsito”, en su Artículo 49, “Medidas mínimas de tránsito”, detalla que, los reglamentos de tránsitos y demás normatividades aplicables de la Federación, Entidades Federativas y Municipios tendrán que regirse bajo características mínimas entre las cuales se encuentran las siguientes relacionadas a las motocicletas: IX. El uso obligatorio de casco para personas conductoras y pasajeros de motocicletas que cumpla con la Norma Oficial Mexicana aplicable en la materia y XII a). Para las personas que conduzcan motocicletas queda prohibido hacerlo con una alcoholemia superior a 0.1mg/L en aire espirado o 0.02 g/dL en sangre. También en la misma Ley, ahora en el Título tercero “De la Distribución de Competencias”, Capítulo I “De la Distribución de Competencias y Coordinación”, en el Artículo 67 “De las Entidades Federativas”, parte XIX, se dicta que corresponde a las entidades federativas realizar los operativos de control de uso de cascos en motociclistas (Ley General de Movilidad y Seguridad Vial, 2022).

En el Estado de Zacatecas, México, el Reglamento General de la Ley de Transporte, Tránsito y Vialidad del Estado de Zacatecas, sección II “Del equipamiento y condiciones de los vehículos”, en su Artículo 27, detalla las partes con las que debe estar provista la motocicleta, las cuales solamente toman en cuenta el uso de luces, espejos retrovisores, frenos delanteros y frenos

traseros. En la sección V referente a “los motociclistas”, el artículo 70 trata acerca de las obligaciones que deben cumplir al transitar por vías públicas las cuales son: respetar el número de ocupantes, se prohíbe que dos o más motocicletas transiten en posición paralela en un mismo carril, no transitar sobre las aceras y áreas reservadas al uso exclusivo de peatones, usar el sistema de alumbrado cuando sea de noche o cuando durante el día no hubiere suficiente visibilidad, los conductores de motocicletas y, en su caso, sus acompañantes, deberán usar casco y anteojos protectores, no sujetar su vehículo a otros que transiten por la vía pública, y no llevar carga que dificulte su visibilidad, equilibrio, adecuada operación o constituya un peligro para sí u otros usuarios de la vía pública. Además, en el artículo 71 de la misma sección trata el tema de los elementos que deben componer el casco de seguridad para motociclistas, en el cual se detalla lo siguiente: I. Cáscara exterior dura y lisa, con el perfil de la cabeza y con relleno amortiguador integral de alta densidad. Acolchado flexible, adherido al relleno que ajuste el casco perfectamente a la cabeza, puede estar cubierto por una tela absorbente; II. Debe cubrir como mínimo la parte superior del cráneo partiendo de una circunferencia que pasa dos centésimas de metro por arriba de la cuenca de los ojos y de los orificios auditivos. No son aptos para la circulación los cascos de uso industrial u otros no específicos para motocicletas, y III. Contar con un sistema de retención, de cintas y hebilla de registro, que pasando por debajo del mentón sujete correctamente el casco a la cabeza (Reglamento General De La Ley De Transporte, Tránsito Y Vialidad Del Estado De Zacatecas, 2017).

En México, en la actualidad existe la Norma Oficial Mexicana NOM-206-SCFI/SSA2-2018, Cascos de seguridad para la prevención y atención inmediata de lesiones en la cabeza de motociclistas-Acciones de promoción de la salud-Especificaciones de seguridad y métodos de prueba, información comercial y etiquetado, la cual fue publicada en el Diario Oficial de la Federación en fecha 29/05/2018. Esta norma tiene como objetivo “establecer las especificaciones, métodos de pruebas para los cascos de seguridad para usuarios de motocicleta (motociclistas) y otros usuarios de vehículos a motor, así como promover su uso para prevenir y disminuir la gravedad de las lesiones en la cabeza, y establecer la información comercial y etiquetado que ostentan los cascos de seguridad para motociclistas en los Estados Unidos Mexicanos”(DOF - *Diario Oficial de La Federación*, 2018).

“En los sectores público y legislativo, sigue existiendo una importante controversia política que ha dado lugar a un impulso para mantener las leyes de cascos de cobertura parcial y derogar las leyes de cascos universales en muchos otros” (MacLeod et al., 2010). La evaluación de leyes

relacionadas a la seguridad vial es posible, particularmente cuando se refiere a una intervención específica, como el uso del casco o el límite de velocidad (Araujo et al., 2017).

2.1.4 Casco protector

Se han propuesto nuevas técnicas para evitar accidentes de tránsito que involucran a las motocicletas, estas van desde mecanismos de detección de carriles, sistemas de visión de análisis de tráfico, redes vehiculares y sistemas de estimación de cansancio, pero, “estudios basados en evidencia indican que el uso de cascos es el mejor método de prevención para la morbilidad y mortalidad por accidentes” (Araujo et al., 2017). “Se ha demostrado previamente que los cascos protectores reducen el riesgo de muerte y lesiones en la cabeza en colisiones de motocicletas en casi un 42 % y un 69 %, respectivamente”(Tabary et al., 2021). Aunque se pueden señalar algunos problemas sobre los cascos de motocicleta, como el hecho de que su uso disminuye la visión de los motociclistas, los beneficios del casco y su uso es aconsejado por varios estudios (Fernandes & Alves De Sousa, 2013).

“Los motociclistas tienen un alto riesgo de lesiones en choques de tránsito y la cabeza es una de las áreas más sujetas a lesiones graves y fatales”(Fernandes & Alves De Sousa, 2013). Estudios que abarcan décadas anteriores han encontrado que la lesión en la cabeza es el tipo de lesión más común en las víctimas autopsiadas de accidentes de motocicleta (41,4 %)(Faduyile et al., 2017). “En particular, la lesión en la cabeza es una causa común asociada de muerte y discapacidad a largo plazo después de un accidente de motocicleta. A pesar de estos hechos, sigue existiendo una controversia en curso en cuanto a las ventajas de supervivencia y discapacidad para los motociclistas que usan cascos de motocicleta”(MacLeod et al., 2010).

La función principal de los cascos de motocicleta es la prevención de lesiones de cráneo y lesiones cerebrales, esto lo hacen al disminuir la cantidad de energía de impacto que llega a la cabeza, lo que reduce la gravedad o probabilidad de tales lesiones. “Además de proteger la cabeza en choques de motocicleta, los cascos mantienen la comodidad de la cabeza reduciendo el ruido del viento y actuando como un escudo contra las ráfagas de viento, las inclemencias del tiempo y cualquier tipo de objeto”. (Fernandes & Alves De Sousa, 2013).

Las principales partes del casco son dos, el forro de espuma y la carcasa. La función del revestimiento de espuma es absorber la mayor parte de la energía de impacto, mientras que la función de la carcasa es el resistir a la penetración de cualquier objeto exterior y distribuir la carga

de impacto en un área de espuma más amplia, aumentando así la capacidad de absorción de energía del revestimiento de espuma. (Shuaeib et al., 2002).

En la Figura 6, se muestran los cascos para los motociclistas que se clasifican en: Casco integral (Full Face Helmet, FFH), Casco modular o abatible (), Casco abierto (), Medio casco, Off-road, y Dual-sport (*Motorcycle Legal Foundation, 2021*).



Figura 6. Tipos de cascos (*Motorcycle Legal Foundation, 2021*).

El casco integral es el más seguro de todos, ya que ofrece la mayor cobertura alrededor de la cabeza y el cuello. Una característica distintiva del casco integral es la mentonera, que es una característica de seguridad crucial de la que carecen muchos cascos (*Motorcycle Legal Foundation, 2021*). Como se muestra en la Figura 7, la mentonera de los cascos integrales es la región con mayor número de impactos, cabe mencionar que los impactos más severos se producen en la parte delantera del casco. (Khosroshahi et al., 2015).

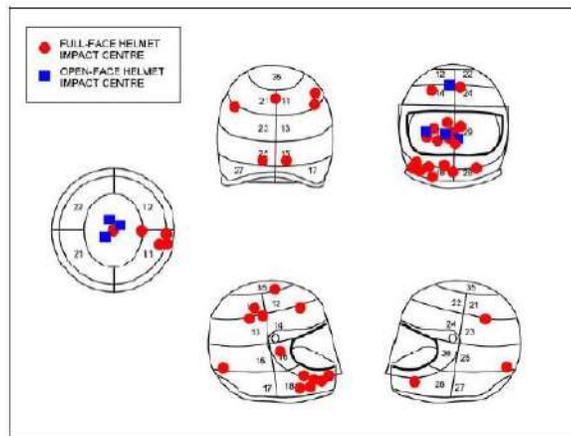


Figura 7. Puntos de impacto aproximados en cascos de motocicletas.(Khosroshahi et al., 2015).

En los cascos modulares la principal característica es que la mentonera y la visera se pueden levantar para abrir la parte delantera del casco, aunque esta característica disminuye la seguridad brindada al motociclista debido a la estructura de la bisagra. Los materiales y el ajuste son similares a los del casco integral. Incluyen una visera para protección de los ojos y ocasionalmente incluyen una visera interna secundaria para protección ocular adicional contra la luz solar. Es el segundo tipo de casco más seguro, sólo detrás del tipo integral (*Motorcycle Legal Foundation, 2021*).

Los siguientes son los cascos abiertos, los cuales cubren la parte superior, laterales y trasera de la cabeza, pero dejan expuesta la cara del usuario. En sus áreas de cobertura se considera que son igual de seguros que los integrales. Generalmente vienen equipados con visores faciales parciales o completos para proteger los ojos y la cara de la luz solar, pero te dejan expuesto a inclemencias del tiempo o algún objeto exterior (*Motorcycle Legal Foundation, 2021*).

En cuanto a la categoría de Medio casco se detalla en el mismo trabajo que solo cubren la parte superior de la cabeza y el área desde la frente hasta las cejas y por lo tanto brindan una protección mínima. Lo único positivo es que estos cascos proporcionan un excelente flujo de aire.

Los categorizados como Off-road están diseñados tal y como su nombre indica, para circular en caminos de tierra. Generalmente no proporcionan protección en la parte de los ojos. Están equipados con una visera más grande y una mentonera más acentuada para un mejor flujo de aire. Hay muchas opciones en cuanto compuestos, las cuales incluyen fibra de vidrio, Kevlar y fibra de carbono. Estos materiales ofrecen una gran resistencia y son livianos para evitar que la cabeza y el cuello se cansen después de un largo tiempo de conducción (*Motorcycle Legal Foundation, 2021*).

Para finalizar con los tipos de cascos están los Dual-sport los cuales son una mezcla entre los integrales y los Off-road. Ofrecen una visera de protección para los ojos más grande que uno integral, pero también pueden ajustarse en una posición hacia arriba para el uso de goggles, y tienen una mentonera más chica que los Off-road. son más acolchados en su interior y brindan una excelente comodidad.

Todos los cascos certificados deben pasar por pruebas donde se busca que cumplan una serie de requisitos y así garantizar la resistencia de su estructura y la protección brindada a la cabeza. Varias agencias acreditadas regulan, certifican y aprueban la resistencia de las estructuras de los cascos de motocicletas probándolas en varios escenarios de accidentes, como el Departamento de Transporte (Department of Transportation, DOT) y la Fundación Snell en Estados Unidos, la Comisión Económica para Europa (Economic Commission for Europe, ECE) en las comunidades europeas, el Instituto de Estándares Británico (BS) y recientemente en el Reino Unido SHARP(Safety Helmet Assessment and Rating Programme). Estos reguladores realizan pruebas simplificando los casos de accidentes de motocicleta. Una de las pruebas es la prueba de impacto, que tiene el potencial más alto para verificar el rendimiento estructural del casco mediante la evaluación de la aceleración máxima y los criterios de lesiones en la cabeza (Head Injury Criteria, HIC) en el simulador de cabeza asignado. Por lo tanto, la prueba de impacto se usa y estudia como el requisito esencial de la estructura del casco para garantizar su resistencia y así la protección de la cabeza de los pasajeros (Kongwat et al., 2022).

La norma vigente de DOT es la FMVSS 218, en la cual hay cuatro pruebas separadas que un casco debe pasar para obtener la certificación DOT; prueba de impacto, prueba de penetración, prueba de correa de retención y finalmente la prueba de visión periférica. Según el tipo de casco que se quiera certificar las pruebas pueden variar. Todas las pruebas se llevan a cabo en un laboratorio de pruebas debidamente acreditado por el Departamento de Transporte de los Estados Unidos. El estándar actual para cascos de motocicleta de Snell es el SNELL M2020, el cual lo establece la Fundación Snell Memorial ubicada cerca de Sacramento, California. Las pruebas y la certificación de SNELL son voluntarias. Algunas organizaciones sancionadoras de carreras requieren que los cascos estén certificados por SNELL para competir. Para ser aprobados por el estándar deben pasar las siguientes pruebas: prueba de impacto, de desplazamiento, de retención dinámica, de impacto en la mentonera y dos pruebas de penetración distintas, para la carcasa y para el protector facial. Para ECE la norma actual es la 22.05 ECE. Las pruebas que se realiza para ser aprobados por este estándar son las de penetración en mentonera y en diferentes partes de la carcasa, pruebas

en la correa de la barbilla y en el protector facial en cuanto a durabilidad e interferencia de la visión. En cuanto a BS se tiene el estándar BSI 6658-85. “Algunas de las medidas que el BSI considera mínimas para que pase un casco son las mismas que utiliza la Fundación Snell”. La mayor ventaja de las pruebas SHARP es que cada casco obtiene una calificación, de 1 a 5 estrellas, en lugar de solo pasar o fallar. Las pruebas de impacto se realizan a tres velocidades diferentes. Los cascos se prueban contra superficies puntiagudas y planas. También hay pruebas de rotación para ver cuánta energía de rotación se transferiría a la cabeza de un motociclista durante un choque. Otro estándar es el FIM, el cual es el más nuevo para cascos de motocicleta que se usan en carreras profesionales. Los estándares de prueba de la FIM están establecidos por la Fédération Internationale De Motocyclisme (FIM), en los cuales solo prueba cascos integrales y enfatiza la resistencia de un casco a las fuerzas de rotación, que pueden ser responsables de la mayoría de las lesiones (Parrotte, 2022).

En los últimos años se ha investigado la adopción de nuevas tecnologías en el casco para mejorar la seguridad. La inclusión de sensores de fuerza, e infrarrojos para la detección del uso del casco es un ejemplo, o el uso de GPS y acelerómetros para detectar cuando un accidente ha sucedido o el uso de sensores como los MQ3 y MQ6 en sistemas que puedan advertir al motociclista o a su persona de contacto de emergencia si existe una alta concentración de alcohol (Tabary et al., 2021).

2.2 Inteligencia Artificial

Dada la complejidad de la inteligencia, no es realista esperar una definición comúnmente aceptada en la etapa actual de la investigación, muchos investigadores persiguen cualquier objetivo que sea fructífero, ya sea en la teoría o en la práctica, sin importar si está etiquetado como "IA" o no. (P. Wang, 2019). Enseguida se presentan diferentes definiciones de IA de algunos autores en años recientes.

“La inteligencia general artificial se refiere a la capacidad de una máquina para comunicarse, razonar y operar de forma independiente tanto en escenarios familiares como nuevos de manera similar a un ser humano”(Riedl, 2019). “Coloquialmente, el término inteligencia artificial se aplica cuando una máquina imita funciones cognitivas que los humanos asocian con otras mentes humanas, como aprender y resolver problemas”(Ongsulee, 2017). El campo de la IA se basa en

la informática, las matemáticas, la psicología, la lingüística, la filosofía, la neurociencia, la psicología artificial y muchos otros (Ongsulee, 2017).

“La inteligencia artificial (IA) se ha vuelto importante en las últimas décadas debido a sus vastas aplicaciones en el mundo real. Los ejemplos incluyen diagnóstico médico, reconocimiento facial, robótica, aplicaciones de Internet, minería de datos, aplicaciones industriales, etc” (Górriz et al., 2020).

2.2.1 Aprendizaje Automático

El aprendizaje automático (Machine Learning, ML por sus siglas en inglés) es el subcampo de la IA que, da a las computadoras la capacidad de aprender sin ser programado explícitamente (Ongsulee, 2017). EL ML está basado en algoritmos que hacen que el sistema aprenda desde su experiencia, es decir, el sistema se vuelve inteligente con el tiempo sin necesidad de una intervención humana (N. Sharma et al., 2021). “Es uno de los campos técnicos de más rápido crecimiento en la actualidad, se encuentra en la intersección de la informática y la estadística, y en el núcleo de la inteligencia artificial y la ciencia de datos”(Jordan & Mitchell, 2015).

El ML explora el estudio y la construcción de algoritmos que pueden aprender y hacer predicciones sobre los datos; dichos algoritmos superan el seguimiento de instrucciones de programas estrictamente estáticos al hacer predicciones o decisiones basadas en datos a través de la construcción de modelos inteligentes (Ongsulee, 2017). No existe un único tipo de algoritmo único que sea mejor para resolver un problema, el tipo de algoritmo empleado depende del tipo de problema que desee resolver, el número de variables, el tipo de modelo que mejor se adapte, etc. (Mahesh, 2018). Dos de los métodos de aprendizaje automático más adoptados son el Aprendizaje supervisado y el Aprendizaje No Supervisado.

Los algoritmos de Aprendizaje Supervisado se entrenan usando ejemplos etiquetados, como una entrada donde se conoce la salida deseada. El algoritmo aprende comparando su salida real con las salidas correctas para encontrar errores, para después hacer modificaciones en el modelo durante su entrenamiento. A través de métodos como clasificación, regresión y predicción, el aprendizaje supervisado utiliza patrones para predecir los valores de la etiqueta en datos adicionales sin etiquetar.

Por otra parte, el Aprendizaje No Supervisado analiza datos que no tienen etiquetas, al sistema no se le dice cuál es la "respuesta correcta". Su objetivo es explorar los datos y encontrar alguna estructura en estos. Otras dos metodologías que son menos usadas son el aprendizaje semi-

supervisado y de refuerzo (Ongsulee, 2017).

Según lo descrito en (Paleyes & Lawrence, 2022), es posible generar un modelo de ML siguiendo una serie de pasos o flujo de trabajo, el cual es un proceso cíclico que permite que el proyecto de aprendizaje automático sea eficiente, y se puede resumir en 4 pasos principales:

- **Manejo de datos**, el objetivo es recolectar y preparar los datos necesarios para generar el modelo de aprendizaje;
- **Aprendizaje del modelo**, en este paso se selecciona el algoritmo a utilizar y se entrena;
- **Prueba del modelo**, se enfoca en que el modelo generado cumpla con la función principal para la que fue creado y con los requerimientos de desempeño;
- **Despliegue del modelo**, se trata de la integración de modelo entrenado en un sistema para su consecuente uso.

Cabe mencionar que esta definición de etapas principales para la generación de un modelo de ML no es necesariamente la norma a seguir en las aplicaciones de escenarios reales, pero es una buena descripción que puede descomponerse en pasos más específicos en cada etapa (Paleyes & Lawrence, 2022).

2.2.1.1 Aprendizaje Profundo

El Aprendizaje Profundo (Deep Learning o DL), es una rama sobresaliente de la inteligencia artificial, ver Figura 8, que se ha ampliado en los últimos años (Chai et al., 2021), y que puede trabajar con una gran cantidad de datos y encontrar sus características significativas de forma automática y eficiente (Chai & Li, 2019). Es parte de una familia más amplia de métodos de aprendizaje automático basados en el aprendizaje de representaciones de datos (Ongsulee, 2017). El DL incorpora modelos computacionales y algoritmos que imitan la arquitectura de las redes neuronales biológicas en el cerebro (Artificial Neural Networks, ANN).

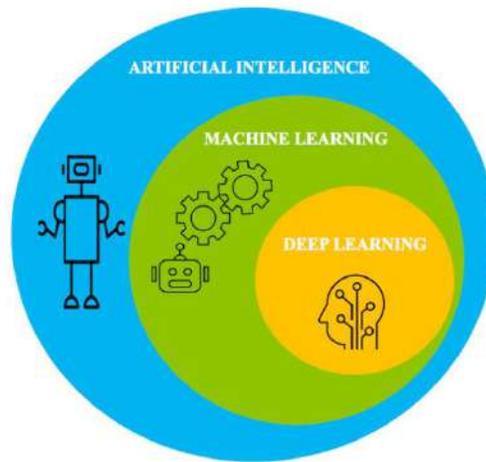


Figura 8. El DL como subconjunto de ML, que a su vez es subconjunto de IA.(Madan & Madhavan, 2020).

Existen tres principales razones que están causando el auge del DL, el aumento en las capacidades de procesamiento de chips como por ejemplo las unidades de GPU, la reducción del costo del hardware informático y los avances que han sido considerables en los algoritmos de ML(Guo et al., 2016).

La investigación en el DL intenta hacer mejores representaciones y crear modelos para aprender de tales representaciones a partir de datos no etiquetados a gran escala. Una observación (por ejemplo, una imagen) se puede representar de muchas maneras, como un vector de valores de intensidad por píxel, o como regiones de forma particular, etc., de las cuales algunas de estas representaciones son mejores que otras simplificando la tarea de aprendizaje (Ongsulee, 2017). Las aplicaciones del DL según Chai & Li, (2019) se puede resumir en varios campos principales como lo son: visión computacional (CV), Procesamiento del Lenguaje Natural (NLP) y Reconocimiento de Video/Habla (V/SP). Algunos de los métodos de DL más exitosos involucran redes neuronales artificiales, que están inspiradas en el modelo biológico de 1959 propuesto por David H. Hubel y Torsten Wiesel, quienes encontraron dos tipos de células en la corteza visual primaria: células simples y células complejas (Ongsulee, 2017).

Las redes neuronales artificiales (ANN) son sistemas de procesamiento computacional que se inspiran en gran medida en la forma en que funcionan los sistemas nerviosos biológicos (como el cerebro humano). Las ANN se componen principalmente de una gran cantidad de nodos computacionales interconectados (denominados neuronas), cuyo trabajo se entrelaza de manera distribuida para aprender colectivamente de la entrada con el fin de optimizar su salida final. La estructura de una ANN se puede ver en la Figura 9, donde la capa de entrada es alimentada

usualmente con un vector multidimensional de datos, enseguida esta información pasa a las capas ocultas que toman decisiones a partir de la capa anterior y así ponderan como un cambio estocástico de la misma capa perjudica o mejora el resultado final de la red, este proceso se conoce entonces como el proceso de aprendizaje (O'shea & Nash, 2015).

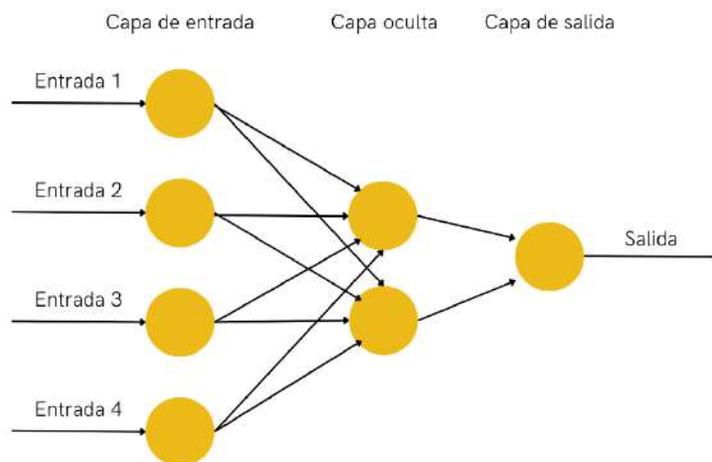


Figura 9. Estructura básica de una ANN.

En los últimos años, el DL ha sido ampliamente estudiado en el campo de la visión artificial y, como consecuencia, han surgido una gran cantidad de enfoques relacionados. En general, estos métodos se pueden dividir en cuatro categorías según el método básico del que se derivan: redes neuronales convolucionales (CNN por sus siglas en inglés Convolutional Neural Networks), máquinas de Boltzmann restringidas (RBM), codificador automático (Autoencoder) y codificación dispersa (Sparse Coding) (Guo et al., 2016).

2.2.1.1.1 Redes Neuronales Convolucionales

Las CNN son análogas a las ANN en la parte que están compuestas por neuronas que se auto optimizan a través del aprendizaje y son útiles en muchas aplicaciones, especialmente en tareas donde se analizan imágenes (Wu, 2017). Cada neurona recibirá una entrada y realizará una operación (como un producto escalar seguido de una función no lineal). Las CNN se utilizan principalmente en el campo del reconocimiento de patrones dentro de imágenes, lo cual permite codificar características específicas de la imagen en la arquitectura, y hace que la red sea más adecuada para este tipo de tareas, al tiempo que reduce aún más los parámetros necesarios para configurar el modelo (O'shea & Nash, 2015). Este tipo de redes neuronales pueden identificar características básicas como bordes en las primeras capas ocultas, formas simples en las siguientes

capas, y características de alto nivel en capas más profundas (Albawi et al., 2018) (LeCun et al., 1998).

Las CNN se utilizan para reconocer patrones visuales directamente a partir de los píxeles de imágenes con variabilidad. Generalmente toma como entrada un tensor de orden 3, por ejemplo, una imagen con filas H , columnas W y 3 canales (canales de color R, G, B), esta entrada pasa secuencialmente a través de una serie de procesamientos, un paso de procesamiento generalmente se le denomina capa, que podría ser una capa de convolución, de agrupación, de normalización, una capa completamente conectada, etc., enseguida se agrega una capa para la propagación del error hacia atrás que permite que los parámetros ajustables de la red aprendan buenos valores en la etapa de entrenamiento y finalmente la última es una capa de pérdida donde se usa una función de costo o pérdida la cual mide la discrepancia que existe entre el resultado de la predicción y el valor real (Wu, 2017). Enseguida en la Figura 10, se muestra un ejemplo de una CNN básica para reconocer dígitos escritos a mano propuesta por (LeCun et al., 1998).

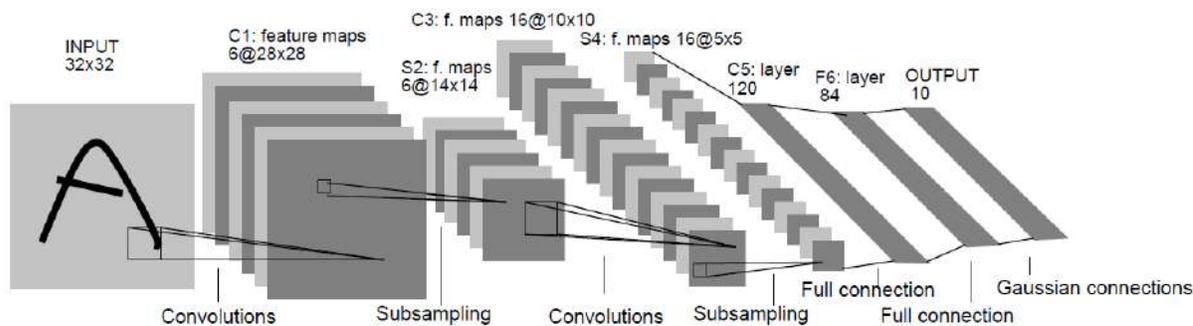


Figura 10. Arquitectura de una CNN para el reconocimiento de dígitos escritos a mano (LeCun et al., 1998)

2.2.1.1.1 Capa de convolución

Entre los componentes básicos y el más representativo de una CNN están las capas de convolución que tienen como objetivo principal el aprender características representativas de los datos de entrada con la ayuda de distintos filtros de convolución que cuentan parámetros (pesos) que se ajustan en el entrenamiento de la red (Gu et al., 2018). Estas primeras capas de convolución pueden reconocer detalles de bajo nivel en las imágenes (Zeiler & Fergus, 2014). Los filtros pasan por toda la imagen de entrada para generar así los mapas de características, matemáticamente el valor de cierta característica en la posición (i,j) en el K -ésimo mapa de la l -ésima capa, $z_{i,j,k}^l$, se puede calcular de acuerdo a la siguiente ecuación (1):

$$z_{i,j,k}^l = W_k^{lT} X_{i,j}^l + b_k^l \quad (1)$$

donde W_k^{lT} es el filtro, b_k^l es el sesgo y $X_{i,j}^l$ es una parte de la imagen o datos de entrada centrada en la posición (i,j) de la l -ésima capa (Gu et al., 2018). Enseguida en la Figura 11 se muestra un ejemplo de esta operación de convolución con un filtro de tamaño 3×3 .

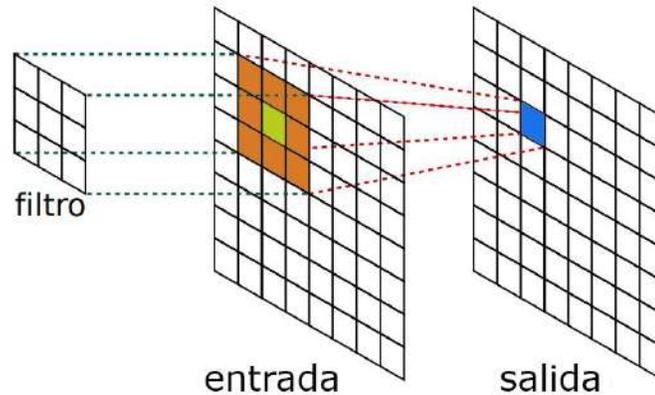


Figura 11. Ejemplo de filtro de convolución.

EL filtro debe recorrer toda la imagen de izquierda a derecha y de arriba hacia abajo, por lo que ese movimiento depende del “paso” que se elija, de esta manera se puede manejar la superposición y controlar el tamaño de la salida que dará la operación. La Figura 12 muestra dada una imagen de 7×7 con un filtro de 3×3 y movemos un solo pixel cada vez tendremos una salida de 5×5 , de manera formal tenemos en la ecuación (2) que dada una imagen de dimensiones $N \times N$ y un filtro de tamaño $F \times F$, con un paso S la salida será:

$$O = 1 + N - F/S \quad (2)$$

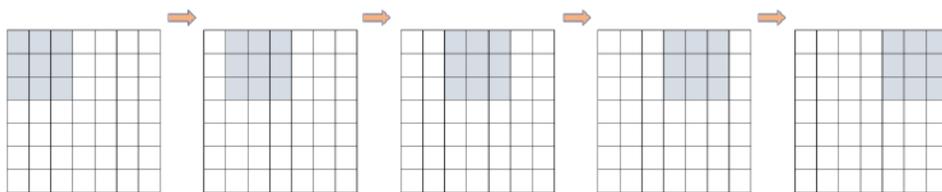


Figura 12. Ejemplo de paso 1 en figura de 7×7 con filtro de 3×3 .

2.2.1.1.1.2 Funciones de activación

La salida de la operación de convolución ahora es la entrada de una función de activación que permite activar la neurona y a la vez transforma la información recibida para que sea la entrada de la capa siguiente (Ding et al., 2018). Entre las funciones de activación, las no lineales son las preferidas cuando se está generando una red neuronal artificial; dado que los problemas del mundo real generalmente tienen datos con características no lineales, la red neuronal debe ser capaz de entenderlos por lo que se vuelve importante el introducir en la arquitectura estas funciones de activación, si no la red neuronal pierde su propiedad más atractiva que es la capacidad de adaptar su comportamiento de acuerdo con las características cambiantes del sistema y actuaría como un modelo de regresión lineal con un rendimiento limitado. Estas funciones limitan la salida de la convolución a un valor finito dependiendo del tipo de función de activación que se elija. Para obtener un buen desempeño del modelo y disminuir el error de los resultados el elegir la función de activación en las capas ocultas de la red es un punto de los más importantes, estas funciones tendrán ventajas y desventajas y su elección dependerá del contexto de uso, es decir, del tipo de sistema que se está diseñando (S. Sharma et al., 2020).

Algunas propiedades que deben tener estas funciones de activación son: a) deben añadir una curvatura no lineal que permita mejorar la convergencia del entrenamiento de la red; b) no deben incrementar la complejidad computacional del modelo de manera cuantiosa; c) no debe ser un obstáculo para el flujo del gradiente al momento del entrenamiento; d) debe mantener la distribución de los datos y facilitar el mejor entrenamiento de la red (Dubey et al., 2022). La función ReLU es una de las más usada y es la que tiene mejores resultados en la mayoría de los casos, aunque existen otras funciones normalmente usadas que enseguida se presentan (S. Sharma et al., 2020).

Función Sigmoide. Es una función no lineal continuamente diferenciable que transforma los valores en un rango entre 0 y 1, generalmente sus salidas se tornan a valores altos y bajos lo que lleva a un problema de desvanecimiento del gradiente en el entrenamiento cuando la red tiene muchas capas ocultas, con esto la actualización de los parámetros (pesos) es mínima o casi nula cuando se usa la técnica de gradiente descendente (Dubey et al., 2022). Su definición matemática se presenta en la ecuación (3) y su gráfica en la Figura 13.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

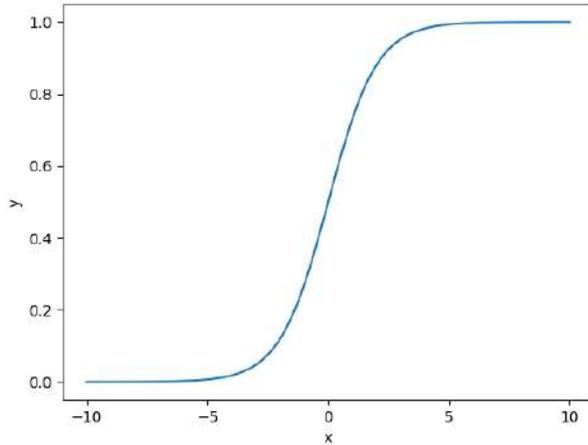


Figura 13. Función Sigmoide (*Activation Functions: Sigmoid vs Tanh*, 2023).

Otra función no lineal es la Tangente hiperbólica la cual es similar a la Sigmoide con la diferencia que esta (tangente hiperbólica) es simétrica cerca del origen, de igual forma es diferenciable y sus valores de salida tienen un rango entre -1 a 1. Su representación matemática se muestra en la ecuación (S. Sharma et al., 2020). Esta función de también tiene los inconvenientes de desvanecimiento del gradiente y complejidad computacional (Dubey et al., 2022). Su representación matemática se muestra en la ecuación (4) y su gráfica en la Figura 14.

$$f(x) = \frac{2}{1 + e^{-2x}} - 1 \tag{4}$$

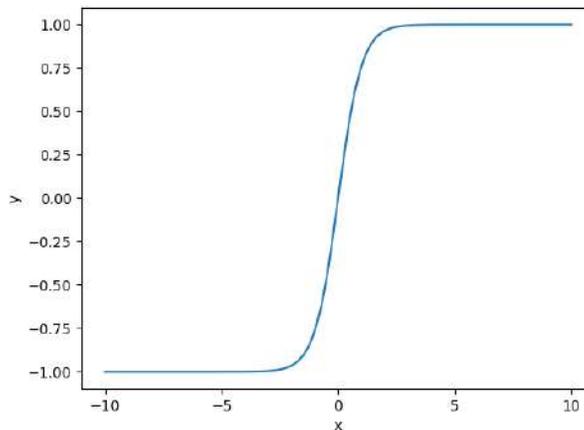


Figura 14. Función Tanh (*Activation Functions: Sigmoid vs Tanh*, 2023).

Por otro lado, la función de activación lineal rectificada (ReLU) se ha vuelto por defecto la elección preferida en las redes neuronales por su simpleza lo que disminuye por lo tanto la complejidad computacional y facilita el entrenamiento de la red. El rango de las posibles salidas de esta función es $[0, \infty)$, y su representación matemática se presenta en la ecuación (5).

$$ReLU = \max(0, x) = \begin{cases} x, & \text{si } x \geq 0 \\ 0, & \text{si } x < 0 \end{cases} \quad (5)$$

Las desventajas de esta función son el desvanecimiento del gradiente para entradas con valores negativos, su limitada no linealidad y su salida sin límite. Hasta la fecha ya se han generado distintas versiones de esta función que buscan solucionar el problema mencionado, algunos de estas versiones son: La función PReLU, RReLU, CReLU, etc. (Dubey et al., 2022).

2.2.1.1.1.3 Capa de agrupación

La capa de agrupación es un paso clave en la arquitectura de una CNN ya que reduce la dimensionalidad de los mapas de características resultantes del paso anterior (convolución y función de activación), esto lo hace manteniendo la información útil y eliminando la irrelevante lo que ayuda a reducir la cantidad de parámetros y consecuentemente la complejidad del modelo (O'shea & Nash, 2015) (Gholamalinezhad & Khosravi, 2020). Este proceso no lineal da como salida un resumen estadístico de los valores cercanos de una región de un mapa de características dado como entrada, por lo que este valor único mejora la precisión y la sensibilidad de la conversión de características para datos de entrada pequeños (Zafar et al., 2022). Además, esta capa de agrupación (pooling) agrega invarianza a la translación la cual es una propiedad muy útil cuando estamos más interesados en si alguna característica está presente en la imagen y no en la posición exacta de tal característica, así el modelo puede generar las mismas salidas sin importar pequeños cambios en la entrada (Ian Goodfellow, Yoshua Bengio, 2017).

Un método de agrupación que generalmente se usa es el de “agrupación máxima”, en el cual se toma el valor más grande de un grupo o vecindario de valores de cierto tamaño. Un ejemplo de este método se muestra en la Figura 15.

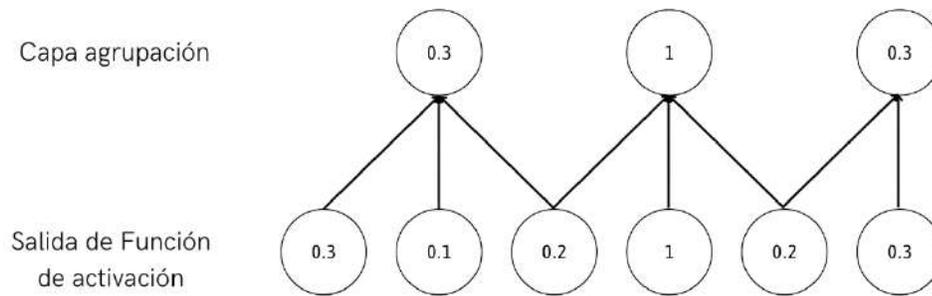


Figura 15. Ejemplo Agrupación máxima con reducción de resolución. El ancho de la agrupación es de 3 unidades y un paso de 2 unidades.

Otro método popularmente usado es el de “agrupación promedio”, donde como lo dice su nombre, se toma como salida el valor promedio del grupo de valores cercanos entre sí (vecinos). (Ian Goodfellow, Yoshua Bengio, 2017).

2.2.1.1.4 Capa totalmente conectada

La salida de una capa ya sea de convolución o de agrupación es transformada en un vector uni-dimensional que se conecta a otro de los componentes básicos de una CNN, la capa totalmente conectada, en esta capa todas las entradas están conectadas a todas las salidas mediante los parámetros entrenables (pesos). Esta capa generalmente es la que más parámetros tiene de todos los tipos de capas presentes en una CNN, un ejemplo es la arquitectura o red AlexNet la cual tiene 60 millones de parámetros entrenables de los cuales 58 millones pertenecen a las capas totalmente conectas o FC por sus siglas en inglés (Fully Connected) (Basha et al., 2020). Esta gran cantidad de parámetros es necesaria para que el modelo pueda adaptarse a funciones discriminantes no lineales complejas presentes en el espacio de características de los elementos de entrada, aunque esto también puede resultar en un sobre-ajuste del modelo, es decir, que el modelo aprenda demasiado bien las características de los ejemplos dados en el entrenamiento inclusive información irrelevante presente en las imágenes por lo que resulta en una clasificación incorrecta a datos de entrada no vistos por la red anteriormente (Yamashita et al., 2018) (Basha et al., 2020). La capa final totalmente conectada de una red típicamente tiene la misma cantidad de nodos que el número de clases, por ejemplo, en un modelo donde se entrena para que se clasifiquen imágenes de perros y gatos la cantidad de clases serían 2. Cada capa totalmente conectada es seguida por una función de activación no lineal como la ReLU mencionada anteriormente. La última capa de la red corresponde a una función de activación que es usualmente diferente a todas las anteriores

presentes en la red, esta necesita ser seleccionada de acuerdo a la tarea, clasificación binaria, clasificación multiclase, regresión a valores continuos, etc. Por ejemplo, la función Softmax es usada para tareas multiclase y la Sigmoide para problemas de 2 clases (Yamashita et al., 2018).

2.2.1.1.5 Entrenamiento de la red

El proceso de entrenamiento de la red implica encontrar los mejores parámetros, filtros o kernels en las capas de convolución y pesos en las capas totalmente conectadas, que minimicen el error entre la salida del modelo y los datos de entrada pertenecientes al conjunto de entrenamiento. El comportamiento del modelo bajo ciertos valores de estos parámetros entrenables es medido por una función de costo o función de pérdida; después los parámetros son actualizados acorde al valor de la función de costo, esto se hace mediante un algoritmo de optimización de nombre “propagación hacia atrás” (Backpropagation) (Yamashita et al., 2018). El entrenamiento de la red puede ser resumido en los pasos siguientes (Hegazy et al., 1994):

1. Preparación de un conjunto de entrenamiento, un vector de entrada (X 's) que se asocia a una salida deseada (D 's).
2. Los parámetros entrenables son inicializados con valores pequeños que generalmente son entre -0.5 y 0.5.
3. El contador de las iteraciones de entrenamiento es incrementado.
4. Un ejemplo es seleccionado del conjunto de entrenamiento como entrada de la red.
5. Se realizan los cálculos dentro de la red capa por capa, las salidas de una capa son las entradas de la siguiente hasta la última capa que genera la salida de la red (O 's).
6. El error entre la salida deseada y la predicción es calculado de acuerdo la ecuación (6):

$$\delta = (D - O) \times O(1 - O) \tag{6}$$

7. Las conexiones de la de la capa de salida de la red son actualizadas por un valor ΔW que se puede calcular siguiendo la ecuación (7) que da inicio a la optimización con el algoritmo de propagación hacia atrás,

$$W_{nuevo} = W_{anterior} + \Delta W \tag{7}$$

$$\text{Donde } \Delta W = \gamma \delta X$$

donde γ es un coeficiente llamado “taza de aprendizaje” con valores de ($0 < \gamma < 1$), lo cual

permite ajustar que tan grandes o pequeños son los ajustes (actualizaciones) de los parámetros de la red.

8. Ahora se actualizan de manera similar al paso 7, los parámetros (pesos) de todas las capas ocultas de la red iniciando desde la capa anterior a la capa de salida y terminando en la primera capa oculta de la red.
9. Se repiten los pasos del 4 al 8 para todos los elementos del conjunto de entrenamiento con lo que completa una iteración. Se calcula un error promedio, por ejemplo, utilizando la fórmula de error cuadrático medio.
10. Si el valor del error calculado en el paso 9 es mayor a un valor objetivo especificado se repite el proceso desde el paso 3 por lo que se genera otra iteración.

2.2.1.2 Transferencia de Aprendizaje

Los modelos de clasificación de imágenes tienen millones de parámetros que si se desea entrenarlos desde cero requiere una gran cantidad de datos etiquetados y mucha potencia informática para obtener buenos resultados. El aprendizaje por transferencia es una técnica que ataja gran parte de esto al tomar una parte de un modelo que ya ha sido entrenado en una tarea relacionada y reutilizarlo en un nuevo modelo (*Tensorflow.Org*, 2022). El concepto de transferencia de aprendizaje inicialmente viene de la psicología educacional, de acuerdo con la teoría de la generalización de la transferencia formulada por el psicólogo C.H. Judd, la habilidad de transferir conocimientos se adquiere a través de la generalización de la experiencia, el único pre requisito es que haya una conexión entre las dos actividades de aprendizaje, lo que quiere decir, que si las similitudes entre los dominios de origen y destino son pocas los resultados no serán los mejores, a este fenómeno se le conoce como transferencia negativa. Ahora, el objetivo de esta técnica de transferencia de aprendizaje es mejorar el rendimiento del modelo destino sin la necesidad de requerir de una gran cantidad de ejemplos etiquetados (Zhuang et al., 2020).

Un punto que en los últimos años ha sido tema de estudio es la categorización de la transferencia de aprendizaje, lo cual se ha hecho con el fin de mejorar el entendimiento de este campo. Hoy en día existen diferentes categorizaciones que se fundamentan en distintos aspectos relacionados al tema, algunos se basan en la interpretación de los datos y sus características los cuales pueden tener distintos objetivos como adaptar del espacio destino, adaptar la distribución de los datos o ajustar sus propiedades. Un ejemplo de este tipo de categorización se apoya en el aspecto de

establecimiento de etiquetas de los datos, es decir, si sólo en el dominio de origen los datos están etiquetados y en el dominio destino no se le categoriza como “transferencia de aprendizaje transductiva”, si en los dos dominios existe la etiqueta se les clasifica como “transferencia de aprendizaje inductiva” y si la etiqueta de los datos es desconocida en ambos dominios pertenecen entonces a la categoría de “transferencia de aprendizaje no supervisada” (Pan & Yang, 2010). Otro enfoque para categorizar la transferencia de aprendizaje se apoya en la interpretación del modelo, el cual desde distintas estrategias buscan alcanzar objetivos como el hacer predicciones más precisas en el dominio destino, adaptar el dominio destino o generar un pseudo etiquetado de datos. (Zhuang et al., 2020). Una de estas categorías es la basada en el control de los parámetros del modelo, donde una estrategia comúnmente usada es la de “compartir parámetros”, aquí como el nombre lo indica se pueden compartir cierta cantidad de parámetros entrenables de una arquitectura ya entrenada a una nueva red y solamente ajustar los demás parámetros, por ejemplo, compartir todos los parámetros ya entrenados excepto los de las últimas dos capas de la red (Zhuang et al., 2020).

2.3 Principales estudios relacionados

A partir de la revisión de literatura del estado del arte llevada a cabo, se seleccionaron los principales estudios relacionados al tema de detección del uso del casco en motociclistas, los cuales se basan en la aplicación o uso de métodos de aprendizaje profundo. De los estudios que enseguida se comenta se extrajo la información más relevante a partir del análisis guiado por la “Metodología para el análisis y revisión crítica de artículos” (Cano & Oliva, 2007).

En el estudio llevado a cabo por Rohith et al. (2019) tiene como objetivo detectar el uso del casco en tiempo real aplicando algoritmos de aprendizaje automático. Para ello utilizan las redes neuronales convolucionales, en específico la arquitectura InceptionV3 (Szegedy et al., 2016). Su idea es que el sistema ayudará a imponer multas a los infractores, y que, por lo tanto, la generación de estas multas obligará a los ciudadanos a utilizar el casco, siendo los usuarios finales del sistema los departamentos de policía. Enseguida se describe de manera breve el proceso del sistema propuesto en el trabajo: En primer lugar, se crea un clasificador en tiempo real para la detección de motocicletas, enseguida se extraen los fotogramas que contienen la moto del archivo de vídeo; el próximo paso es realizar la segmentación de objetos en los fotogramas obtenidos para identificar la clase de motociclista y la clase rechazada; enseguida con la extracción de características de la imagen se podrá clasificar en la clase “con casco” o en la clase “sin casco”;

después de que se identifica a un infractor, la imagen segmentada se guarda en un directorio para su posterior uso. Cabe mencionar que los vídeos son grabados con cámaras de tráfico instaladas en ubicaciones previamente seleccionadas. En cuanto a las contribuciones de este trabajo se puede mencionar que este afirma al reentrenamiento de redes neuronales convolucionales como una herramienta que da buenos resultados cuando la cantidad de datos disponibles es limitada.

Otro trabajo realizado por (Siebert & Lin, 2019) que de igual manera trata de detectar el uso del casco en motociclistas a partir de videos de tráfico urbano utiliza un algoritmo especializado en la detección de objetos de nombre RetinaNet. En esta propuesta se busca detectar el uso del casco en todos los ocupantes de la motocicleta y no sólo en el conductor, se concluye que sus resultados son muy parecidos a la detección llevada a cabo por un humano, y a pesar de tener una gran cantidad de imágenes para entrenar, validar y probar el algoritmo, el entrenar una red desde cero es un aspecto que se debe tomar en cuenta debido a la variabilidad que puede presentarse en las imágenes como lo es la cantidad de luz, el ángulo de captura del video, el clima, etc.

En el artículo de (Wei Jia et al., 2021), aunque sigue enfocado a la detección del casco a partir de videocámaras instaladas en la vía como los dos antes mencionados (Rohith et al. 2019) y (Siebert & Lin, 2019), se propone utilizar YOLOv5 como principal método de detección del casco, el cual es un algoritmo de detección de objetos de una etapa el cual tiene como ventajas una velocidad y precisión mayor a los algoritmos de dos etapas como Faster R-CNN o Cascade R-CNN. La metodología de este trabajo se basa en primero detectar la motocicleta utilizando una versión modificada de YOLOv5 nombrada YOLOv5-MD, después para detectar el casco, de igual manera se basa en YOLOv5 con modificaciones en el ancho y profundidad de la red (YOLOv5-HD). La mayor ventaja que presenta esta propuesta es la velocidad de procesamiento de 135 imágenes por segundo alcanzando una precisión mayor al 99%.

En el presente año 2023 se siguen desarrollando nuevas propuestas para mejorar la seguridad vial, tal como se exponen en el evento “2023 AI City Challenge” (Naphade et al., 2023), donde el desafío número 5 se enfoca en el problema de la detección del casco en conductores de motocicleta a partir de videos de tráfico urbano de una ciudad de la India. Este desafío consta de entrenar un modelo inteligente a partir de una base de datos dada de 100 videos de 20 segundos de duración a 10 fps (fotogramas por segundo) para luego clasificar cada una de las imágenes del conjunto de prueba de igual tamaño que el conjunto de entrenamiento y evaluar su desempeño con la métrica mAP. Uno de los trabajos presentados en este evento es el de (Duong et al., 2023), en el cual se siguen utilizando algoritmos de aprendizaje profundo para la generación de los modelos

inteligentes. En particular ellos utilizan YOLOv8 en las dos etapas de su metodología denominadas detector e identificador, en la primera detectan a la motocicleta y sus ocupantes y al final se identifica si los usuarios portan el casco. Sus resultados alcanzaron un valor de 0.7754 en la métrica mAP con lo que concluyen que su modelo se habría sobreajustado a los datos en la etapa de entrenamiento resultando en el declive del valor final de la métrica. Otro trabajo que se generó en el “2023 AI City Challenge” (Naphade et al., 2023) es el de (Cui et al., 2023), el cual cabe mencionar obtuvo un valor de 0.8340 en mAP siendo la puntuación más alta en el desafío 5 mencionado anteriormente. Para alcanzar los resultados expuestos en esta propuesta su trabajo se basa en 3 partes principales, en la primera se detecta que objetos están presentes en la imagen dada y hace la predicción, esto se genera a partir de ensamblar dos modelos distintos entrenados con el método transformador de detección llamado DETA (Ouyang et al., 2022). En la segunda parte se refina la detección del casco en el pasajero 2 debido a que la base de datos de entrenamiento cuenta con muy pocos ejemplos de esta clase. En este módulo utilizan la plataforma de código abierto Detectron2 (Yuxin Wu et al., 2019) para obtener los cuadros delimitadores que son los datos de entrada de la red resnet que se encarga de clasificar las imágenes en pasajero 2 sin casco o con casco. Finalmente, las salidas del modelo ensamblado y del módulo 2 se envían a un módulo 3 para la corrección de categorización si así fuera necesario, esto se realiza utilizando uno de los más populares métodos de seguimiento por categoría de detección llamado SORT (Bewley et al., 2016). Como mayor aporte de este trabajo podemos concluir que el generar nuevos apartados como parte de un sistema inteligente puede mejorar la detección de objetos de cierta clase de la cual se tienen pocos datos.

Mencionado los objetivos, resultados y aportes de cada uno de los estudios anteriores, la principal diferencia con la propuesta de esta investigación es el enfoque que se tiene para solucionar el problema del uso del casco, es decir, los estudios anteriores se enfocaban en generar ITS “correctivos” los cuales no solucionan en tiempo real la acción del uso del casco, si no que dependen de interactuar con otros sistemas para cumplir con su objetivo; que, en contraste con la propuesta presentada, esta se enfoca en ser un ITS “preventivo”, con el cual se buscará solucionar en tiempo real el problema del uso del casco, desde que el usuario intente iniciar su recorrido.

Capítulo 3. Método y propuesta de investigación

En el presente capítulo se describe la metodología utilizada para la clasificación de imágenes de personas con casco y sin casco mediante el desarrollo del modelo de aprendizaje automático.

3.1 Método de investigación

El método de investigación implementado está basado en el proceso general presentado por (Hernández Sampieri, 2017), el cual se planea llevarlo en 3 etapas descritas gráficamente en la siguiente Figura 16, esto con la intención de analizar al final de cada una de estas etapas el desarrollo y cumplimiento de los objetivos específicos planteados, ver Figura 17.



Figura 16. Propuesta de investigación.

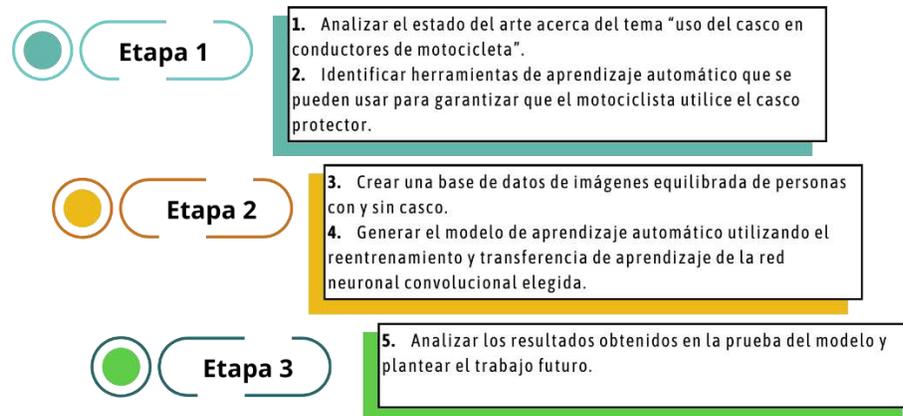


Figura 17. Resultados esperados por etapa 1, 2 y 3.

Los dos primeros puntos "Idea o Tema" y "Planteamiento del problema de investigación" se detallan en el capítulo introductorio del presente trabajo. Para poder iniciar con el proyecto de investigación es necesario tener una idea la cual sirva para resolver un problema. En este caso la idea surge a partir de la conjunción de la experiencia del manejo de las motocicletas y el Procesamiento de Datos, el cual es la Línea Generación y Aplicación del Conocimiento (LGAC) que se desarrolla en la Maestría en Ciencias del Procesamiento de la Información. Teniendo la idea de mejorar la seguridad en la motocicleta a través del procesamiento de datos y llevando a cabo una investigación previa del tema se plantea el problema de investigación.

El siguiente punto 3 "Desarrollo del marco teórico", se desarrolla totalmente en el capítulo 2, el cual una de sus funciones principales es orientar el estudio, en esta fase se indaga en los temas relacionados a la investigación y se presentan las teorías base del estudio (Hernández Sampieri, 2017).

Enseguida el punto 4 "alcance del estudio", que resulta de la revisión de la literatura, tendrá un enfoque descriptivo ya que se busca recolectar imágenes, que serán los datos de entrada del modelo de aprendizaje automático.

La Hipótesis (punto 5), que es una respuesta provisional o suposición sobre las preguntas de investigación (Hernández Sampieri, 2017) y es resultado de los 4 puntos anteriores, se puntualiza en el apartado 1.7 donde se detalla información acerca de su conceptualización.

Para poder resolver nuestro planteamiento del problema de detección del casco en conductores de

motocicleta, el diseño de la investigación (punto 6) de acuerdo a (Hernández Sampieri, 2017) será un diseño catalogado como “cuantitativo experimental puro”. En nuestro experimento se manipulará intencionalmente la variable independiente identificada en el trabajo (imágenes de personas con casco y sin casco) y se analizará qué consecuencias tiene esta manipulación en la variable dependiente (precisión del modelo).

Ahora en la etapa 2 se generará un artículo de investigación el cual será evaluado por expertos buscando su publicación en una revista internacional de alto impacto en el área de transporte o nuevas tecnologías. Esta etapa abarca los puntos 7: Selección de la muestra, 8: Recolección de datos y 9: Análisis de datos.

En la etapa final número 3 de este trabajo de investigación, la cual tiene como objetivo comunicar los resultados y así contribuir al conocimiento científico, se redactó y publicó esta tesis en el repositorio institucional de la Universidad Autónoma de Zacatecas finalizando con la presentación del proyecto en un Examen de Grado ante un Jurado Calificado.

3.2 Artículo, Etapa 2 de la propuesta de investigación.

La prevención es una buena práctica para evitar situaciones riesgosas. La Inteligencia Artificial, específicamente el subcampo del aprendizaje automático puede ayudar a que los sistemas de seguridad en la motocicleta sean mejores, garantizando que el usuario lleve puesto el casco antes de iniciar su recorrido. La tarea de la detección de un objeto (casco), que el cerebro humano la realiza a través del sistema sensorial visual, se puede analizar desde la perspectiva computacional. Por lo tanto, el aprendizaje de representaciones, que se define como un conjunto de métodos que permite alimentar una máquina con datos sin procesar, como lo son las imágenes, y descubrir automáticamente las representaciones necesarias para su clasificación es una opción viable para utilizar en la tarea de detección del casco (LeCun et al., 2015). Enseguida se presenta el artículo titulado “Detection of Helmet Use in Motorcycle Drivers Using Convolutional Neural Network”, correspondiente a la Etapa 2 de la propuesta de investigación (Mercado Reyna et al., 2023).



Detection of Helmet Use in Motorcycle Drivers Using Convolutional Neural Network

Jaime Mercado Reyna ¹, Huizilopoztli Luna-García ^{1,*}, Carlos H. Espino-Salinas ¹, José M. Celaya-Padilla ¹, Hamurabi Gamboa-Rosales ¹, Jorge I. Galván-Tejada ¹, Carlos E. Galván-Tejada ¹, Roberto Solís Robles ¹, David Rondon ² and Klinge Orlando Villalba-Condori ³

- ¹ Unidad Académica de Ingeniería Eléctrica, Universidad Autónoma de Zacatecas, Jardín Juárez 147, Centro, Zacatecas 98000, Mexico; jaime.mercadoreyna@uaz.edu.mx (J.M.R.); carlospino@uaz.edu.mx (C.H.E.-S.); hamurabigr@uaz.edu.mx (H.G.-R.); gatejo@uaz.edu.mx (J.I.G.-T.); ericgalvan@uaz.edu.mx (C.E.G.-T.); rsolis@uaz.edu.mx (R.S.R.)
 - ² Departamento Estudios Generales, Universidad Continental, Arequipa 04001, Peru; drondon@continental.edu.pe
 - ³ Vicerrectorado de Investigación, Universidad Católica de Santa María, Arequipa 04002, Peru; kvillalba@ucsm.edu.pe
- * Correspondence: hlugar@uaz.edu.mx (H.L.-G.); jose.celaya@uaz.edu.mx (J.M.C.-P)

Abstract: The lack of helmet use in motorcyclists is one of the main risk factors with severe consequences in traffic accidents. Wearing a certified motorcycle helmet can reduce the risk of head injuries by 69% and fatalities by 42%. At present there are systems that detect the use of the helmet in a very precise way, however they are not robust enough to guarantee a safe journey, that is why is proposed an intelligent model for detecting the helmet in real time using training images of a camera mounted on the motorcycle, and convolutional neural networks that allow constant monitoring of the region of interest to identify the use of the helmet. As a result, a model was obtained capable of identifying when the helmet is used or not in an objective and constant manner while the user is making a journey, with a performance of 97.24%. Thus, it was possible to conclude that this new safety perspective provides a first approach to the generation of new preventive systems that help reduce accident rates in these means of transport. As future work, it is proposed to improve the model with different images that may violate the helmet detection.

Keywords: helmet detection; deep learning; InceptionV3; convolutional neural network; motorcyclist safety



Citation: Mercado Reyna, J.; Luna-García, H.; Espino Salinas, C.H.; Celaya-Padilla, J.M.; Gamboa Rosales, H.; Galván-Tejada, J.I.; Galván-Tejada, C.E.; Solís Robles, R.; Rondon, D.; Villalba-Condori, K.O. Detection of Helmet Use in Motorcycle Drivers Using Convolutional Neural Network. *Appl. Sci.* **2023**, *13*, 5882. <https://doi.org/10.3390/app13105882>

Academic Editor: Krzysztof Koszela

Received: 18 April 2023

Revised: 3 May 2023

Accepted: 9 May 2023

Published: 10 May 2023



Copyright: © 2023 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

The means of transport have been changing over the last few years, and the use of motorbikes has been increasing, as a result of the growth of the middle class who are looking for affordable vehicles, and also because of the urbanization from which a new demand for mobility is derived, which is mainly has seen coverage by the individual private transport industry [1]. The financing facilities to acquire these vehicles, better fuel economy, their ability to manage on different terrains and in conditions where traffic is congested, and low maintenance costs are major factors driving their use in lower-middle income countries [2,3]. This development inevitably also exposes the users of this means of transport to negative consequences such as traffic accidents, in which the potential damage is usually high for motorcyclists and their passengers, since there is no structure of the motorcycle that protects them as if it happens in four-wheeled vehicles [4].

Road traffic crashes cause more than 1.35 million deaths annually and are the first cause of death in children and young adults; in particular, 28% of these deaths globally correspond to users of two- or three-wheeled vehicles. Among the leading causes of death, serious injury and disability of motorcyclists are head and neck injuries, which

are estimated to result in 50% of fatalities [5]. Correct helmet use is a proven effective intervention, which, decreases by 42% in the risk of fatal trauma and by 69% the risk of head trauma in road crashes [6,7], despite this, in low- to middle-income countries (LMIC), more than 50% of motorcyclists do not use the helmets while riding. There are several factors that are related to this problem such as helmet weight, thermal discomfort, auditory/visual effects and other cultural factors [8]. Globally, 94% of the countries have a national law that require the use of helmets among motorcyclists, but, in a large number of countries the loopholes in these laws potentially limit their effectiveness, so it can be inferred that the fact of the mere enactment of mandatory helmet laws does not lead to improved helmet wearing behavior among motorcyclists [9,10].

The international community should continue promoting actions to improve practices in the areas of road safety management and the implementation in other parts of the world of interventions that have had good results, taking into account different cultural aspects that may affect their effectiveness [6]. For the vehicle design part, certain characteristics and technology must be integrated that improve its safety by avoiding or reducing the risk of injuries for users [11]. Since 2006, different organizations worldwide have collaborated in the creation of a series of manuals in order to provide guidance on the implementation of interventions that can improve road safety, and the first of these manuals was entitled “helmets” in the which purpose was to encourage the use of helmets by motorcyclists [12]; similarly, in 2009 the Asian Injury Prevention Foundation (AIP Foundation) developed the “Global Helmet Vaccine Initiative” (GHVI), which is based on 5 strategies to increase the use of the helmet [13], in the same way, the “International Transport Forum” (ITF), which organizes a global dialogue for better transport, drafted a work for 2022 where priority actions are formulated with the general objective of improving the safety of motorcyclists [14]. Currently, the objective of increasing the use of certified helmets is part of the action plan to improve road safety in the decade 2021–2030 [11].

In order to detect the helmet use by motorcyclists in the traditional way, the personnel responsible for road safety install checkpoints, and visually check that drivers are indeed wearing helmets, otherwise fines are imposed according to the legislation, although this system can be circumvented or evaded by taking an alternate route [8]. As a result of this, several studies have been developed to try to solve the problem of the lack of helmet use and thus reduce deaths and injuries in road accidents involving motorcycles.

Government’s in different countries are trying to mitigate this problem by implementing flexible, effective and low-cost methods. Consequently, Intelligent Transportation Systems (ITS) have been developed, which are advanced applications that combine electronics, communication systems, computers and sensors. These ITS integrate vehicles, their users and the roads to provide real-time information to increase safety in traffic systems. In the development of various ITS for motorcycle and helmet detection, different technologies have been used, such as radar, sound sensors, optical sensors, among others [15]. The available technologies for motorcycle detection and recognition also face two major problems: the computational capacity (since most of them are deployed on the road) and the degree of detection reliability [16]. An example of this is the surveillance methods that use video cameras installed at specific points on the roads to identify offenders who do not wear helmets while riding motorcycles; however, these systems are passive and require human assistance, so their efficiency decreases over a prolonged period of time. Automation of these types of systems can help to have reliable and robust monitoring, as well as significant reducing the amount of human resources necessary for its operation [17], but, taking into account that in most of the streets there are no cameras that are monitoring the traffic, installing cameras in all places cannot be a viable and economically sustainable solution [18].

Related Work

In recent years, combining different image processing techniques with intelligent models has shown to be a good proposal in the task of detecting helmets in motorcyclists,

because the machine learning algorithms, specially the deep learning algorithms can efficiently recognize a helmet in an image or video [17]. Forero et al. [16] proposes to analyze traffic videos with an artificial intelligence model, which uses a pre-trained convolutional neural network to classify motorcycles and detect the use of protective helmet from the morphology of the object, this model obtained as results for the detection of motorcycles an accuracy of 97.14% and 85.29% for the detection of the helmet. In the work of Singh et al. [17], they reports the accuracy obtained in the training stage of the models, where the use of machine learning algorithms as classifier varies, which are K-nearest neighbor, decision trees, support vector machines and convolutional neural networks, the latter being the ones that have delivered the best results with 99.1% accuracy in the classification of drivers with and without helmet. Another example of the use of these tools is the one proposed by Rohith et al. [19] where from analyzing traffic videos, the helmet detection model in which the InceptionV3 pre-trained convolutional neural network is used, a 74% accuracy was obtained in the validation stage of the proposal. Similarly, Shine et al. [20], propose identify the use of helmet, analyzing traffic videos obtained from a fixed position, with the difference that they use a custom convolutional neural network, reaching an accuracy of 96.98%. Lin et al. [21] proposes a model by detecting helmet use where Inception V3 retraining is used together with the Multiple Transfer Learning Technique (MTL), achieving a final test accuracy of 80.6%. Other proposals use object detection algorithms based on convolutional neural networks belonging to the YOLO (You Only Look Once) series to perform the helmet detection task from images obtained of the urban traffic. Cheng et al. [22] uses the algorithm called SAS-YOLOv3-tiny that obtained 71.6% in the accuracy metric and 80.9% for Recall in its testing stage. Similarly Jia et al. [23] use in the stage where the helmet is detected a improved version of the fifth version of YOLO which is superior in terms of speed and precision to its predecessors, called YOLOv5-HD, in this work the Precision reaches 98.0% and Recall 97.2%. Another proposal by Waris et al. [24], is based on the use of another deep learning algorithm called Faster R-CNN, which consists of two main modules RPN and Fast R-CNN, which, in the end, try to find the helmet in a given image, this work achieved an accuracy of 97.69%.

In other works that aim to improve motorcycle safety, it is proposed to develop smart helmets. Mohd Rasli [25], proposes to detect the user's head with a force sensor installed in the helmet, this signal is sent from a transmitter circuit to a receiver by means of a radio frequency module in order to control the ignition of the motorcycle and produce a sound to remind you of helmet use.

On the other hand, there are several ITS developed for four-wheeled vehicles that can be introduced and adapted to motorcycles, one of them is the seat belt reminder system, which can be adapted in the case of helmet use, as over the years reminder systems have played a vital role in increasing seat belt use [15]. The work presented by Kashevnik et al. [26], proposes to detect the use of the seat belt based on the analysis of images obtained with a camera inside the vehicle cabin, they generate a model based on the use of the architecture of a neural network named YOLO-Net, which classified the images into three categories, seat belt correctly fastened, seat belt fastened behind the back, and seat belt not on, reaching an accuracy of 93%.

The aim of this research work is to generate an artificial intelligence model for real-time detection of helmet use in motorcyclists, in order to improve the safety of these vehicles with prevention and not with the correction of the activity (helmet use). This intelligent model is based on the use of image processing and deep learning techniques.

The paper is organized as follows: Section 2 explains the materials and methods used to data acquisition through video capturing. Section 3 presents the results obtained from the proposed methodology for helmet detection in real time. Section 4, the results obtained in the previous section are discussed in order to highlight the contribution of the work in relation to the literature. Finally, Section 5 concludes and proposes future work for improvement detection of helmet.

2. Materials and Methods

This proposal base the detection of helmet use from the analysis of images, which can be obtained with a monitoring system integrated into the motorcycle, and not as an external monitoring system, this in order to ensure that the helmet use is under surveillance since the driver wishes to start his journey.

The Figure 1 shows the methodology followed for the development of the helmet detection project in motorcyclists. In the first stage, the videos that will serve as input data are collected. In stage 2, data preprocessing consists of extracting a certain number of frames (images) from the videos, which will be used in stage 3 for training and validation of the deep learning model in order to classify motorcyclists with and without helmets in real time, in this last step different deep learning techniques are integrated. Each stage is explained in detail in the next subsections.

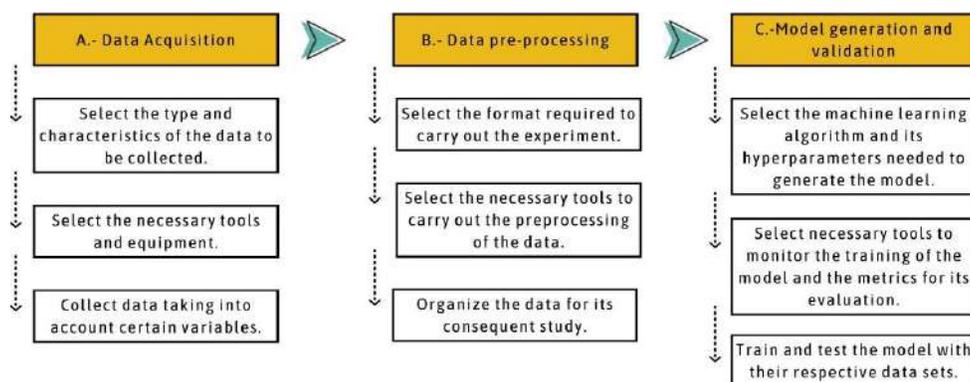


Figure 1. Proposed methodology for the generation of an intelligent model for helmet detection in motorcyclists.

2.1. Data Acquisition

Consists of measuring or capturing the relevant information for the research work [27]. According to the proposal presented, images of people with and without helmets will be collected, since deep learning methods can work with audio data, images, etc. and automatically learn the necessary representations to perform detection or classification tasks [28]. This phase will be divided into two sections, planning and execution.

In the planning, a motorcycle brand Vento 2021 model “Rocketman” was selected, which is the second best-selling motorcycle brand in Mexico since it is the geographical area where the research study was conducted [29]. Next, a GoPro HERO5 Session 10 MP 4 K Ultra HD Wifi-Sports Camera (4 K Ultra HD, 3840 × 2160 Pixels, 120 fps, 1280 × 720, 1920 × 1080, 2560 × 1440, 3840 × 2160 Pixels, 720 p, 960 p, 1080 p, 1440 p, NTSC, PAL) was chosen as the device to record the drivers, because it has different capture modes and video settings, as well as the feature of incorporating a micro SD memory for storing the files generated and its ease of mounting on motorcycles. Table 1 presents the video configurations used in the experimentation. Then, the study subjects who participated in the tests were selected, where 13 were students of the Autonomous University of Zacatecas, with ages between 21 and 30 years old and 3 other drivers were residents of the state of Zacatecas, Mexico with ages between 30 and 41 years old. In this experiment, a total of 16 participants were used, of which 7 are women and 9 are men as a first approximation for a new approach to safety, based on the fact that the number of male drivers in LMIC is usually greater than 90%, as can be seen in the data presented by Datos México [30]. Finally, it was determined that the helmets to be used would be certified full-face and modular

helmets, for the following reasons: they are the safest helmets for motorcycle riders [31] and finally for being in line with objective 7 planned by the World Health Organization [11].

Table 1. Video settings of video camera GoPro Hero 5 Session.

Settings	Parameters
Video Resolution	1080 × 920 (pixels)
Aspect Ratio	16:9
Field of view	Medium scope
Frames per Second	30

In the execution part, and given that this proposal is intended to serve as the basis for the development of an intelligent system for monitoring the use of the helmet which is part of the motorcycle itself, the acquisition of the videos must be carried out from a position that meets two points, one, where don't obstruct the user's visual field and two, where don't compromise the visualization of data presented on the motorcycle's dashboard. That said, and as shown in Figure 2, the camera will be installed on the handlebars of the motorcycle on the side of the dashboard at a height where it does not significantly affect the user's field of vision.



Figure 2. Position of the camera mounted on the motorcycle.

Once the position of the camera is selected, the videos will be recorded. Before starting the capture, the participants will receive instructions to try to start the motorcycle while carrying out the activity, simulating that the helmet use monitoring system was already installed, so that the images collected are useful for work.

In this part, in order for the model to be robust, that is, that it can correctly classify the use of the helmet, it will be sought to have to a certain extent variety in terms of the use of personal items such as caps, face masks and sunglasses by the participants.

2.2. Data Pre-Processing

In this section, the objective task will be extract certain number of frames per second (FPS) in JPG format from the videos obtained in the data acquisition stage, for this it's necessary to develop a script for the extraction of these frames (images) from each of the videos in Python language with jupyter notebook, which is a web application for creating and sharing computational documents [32], below is the pseudo code for this step.

Pseudo code for extract frames.

```
#import the necessary libraries
#define the constant SFPS
SFPS = 4
#define a function to format timedelta objects
function formattimedelta(td):
```

```

        result = string(td)
        result, ms = result.split(".")
        ms = int(ms)
        ms = round(ms / 1e4)
        return f(result)
#define a function to get the list of durations where to save the frames
function getsavingframesdurations(cap, savingfps):
    s = []
    get clip duration with cv2
    for i in range(0, clipduration, 1 / savingfps):
        s.append(i)
    return s
#set the working directory
#open the video file with functions of cv2
#get the FPS of the video with functions of cv2 (fps)
set a variable to the minimum value of SFPS and the fps
savingframespersecond = min(fps, SFPS)
#get the list of duration spots to save (savingframesdurations)
count = 0
#start a loop that runs until there are no more frames to read
while True:
    #read a frame
    if not is read:
        break
    frameduration = count / fps
    try:
        #get the earliest duration to save (closestduration)
    except:
        #the list is empty, all duration frames were saved
        break
    if frameduration >= closestduration:
        #save the frame (framedurationformatted)
        #name the frame
        #drop the duration spot from the list, since this duration spot is already saved
        count += 1
#release the capture

```

Once the images have been extracted and labeled in their corresponding category, the database must be divided into training and test sets to avoid the over-fitting, that is, when the model describes all the data perfectly well without being really acceptable [33]. The pseudo code for this last data pre-processing step is shown below.

Pseudo code for separating data into training and test sets.

```

import the necessary libraries
Set the path to the directory containing the files to be moved
#Get a list of all files in the directory
#Check the total of files in the directory
#Calculate the number of files to be moved (30% for test set)
#Start a for loop in the range of the number of files to move
    #Choose a random file from the directory
    #Set the source path to the chosen file
    #Set the destination path to the target directory
    #Move the file
    #If the source and destination are the same file

```

```

        print("Source and destination represent the same file.") #If
        there is a permission error
        print("Permission denied.")
    #For any other error
    except:
        print("Error occurred while copying file.")
        print(aa)
#Print the number of files moved
    
```

For the hardware part, all the data preprocessing and the following model generation section will be carried out on a computer with the following characteristics: brand: lenovo, model: ideapad 3 (15⁰⁰), processor: AMD RYZEN 7 5700U, RAM memory: 16 GB.

2.3. Model Generation and Validation

The use of deep learning tools such as Convolutional Neural Networks (CNN) has had excellent results in applications that deal with unstructured data such as images. This algorithm, which is based on the human visual system and takes its name from a linear mathematical operation between matrices called convolution [34], can recognize visual patterns directly from the pixels of an image [35].

These networks (CNN) typically contain three main components; the main one is the convolution operations, that consists of taking a group of nearby pixels from the input image and mathematically operating these groups against a small matrix called kernel, that goes through the entire image to finally produce a new matrix that contains certain distinctive features of the image, an example of this operation is shown in Figure 3, and we can see it described mathematically in Equation (1);

$$Y = f\left(\sum_{i=1}^n X_i * W + b_i\right) \tag{1}$$

where n refers to the number of elements, $*$ denotes the operation of convolution, b is the bias of outputs, W is a filter of size $K_x \times K_y$ and f is the activation function.

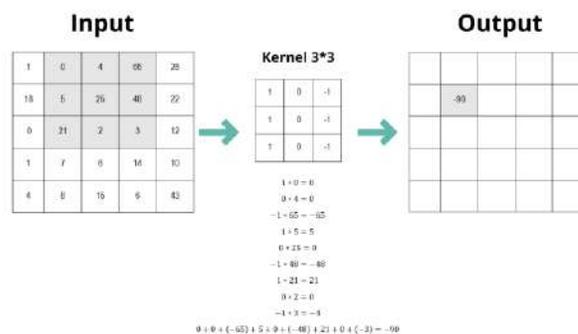


Figure 3. Example of convolution operation.

Another important component is pooling operations, which reduce the size of images while preserving the most important features of the image; finally, we also have nonlinear activation operations called activation functions, which are necessary to avoid learning trivial linear representations of the image [36].

In the proposed methodology will use Tensorflow [37], a second-generation technology developed by Google, specialized for the implementation of large-scale machine learning models, which supports the use of deep learning models such as CNNs. Today Google has

made available to researchers different pre-trained models, such as Inception v3, which has been shown to achieve greater than 78.1% accuracy in training the data set with more than 1 million images entitled ImageNet [38]. One of the main characteristics of Inception networks in scenarios where memory or computational capacity are limited, is that the computational cost required to run them is much lower than other types of networks such as VGGNet or its successors. Table 2 shows the architecture of the Inception v3 CNN, and the Figure 4 shows a high level diagram of the model, where 3 main sections can be identified, number one the basic convolutional block that is used for feature extraction, number two the improved inception module in which multi-scale convolutions are conducted in parallel, and the convolutional results of each branch are further concatenated, and number 3 the classifier [36,39].

Table 2. Inception V3 architecture. Where filter concat 1 each 5×5 convolution is replaced by two 3×3 convolution, filter concat 2 after the factorization of $n \times n$ convolutions and filter concat 3 expanded the filter bank outputs.

Type	Patch Size/Stride	Input Size
conv	$3 \times 3/2$	$299 \times 299 \times 3$
conv	$3 \times 3/1$	$149 \times 149 \times 32$
conv padded	$3 \times 3/1$	$147 \times 147 \times 32$
pool	$3 \times 3/2$	$147 \times 147 \times 64$
conv	$3 \times 3/1$	$73 \times 73 \times 64$
conv	$3 \times 3/2$	$71 \times 71 \times 80$
conv	$3 \times 3/1$	$35 \times 35 \times 192$
3 × Inception	Filter concat 1	$35 \times 35 \times 288$
5 × Inception	Filter concat 2	$17 \times 17 \times 768$
2 × Inception	Filter concat 3	$8 \times 8 \times 1280$
pool	8×8	$8 \times 8 \times 1280$
linear	logits	$1 \times 1 \times 2048$
softmax	classifier	$1 \times 1 \times 1000$

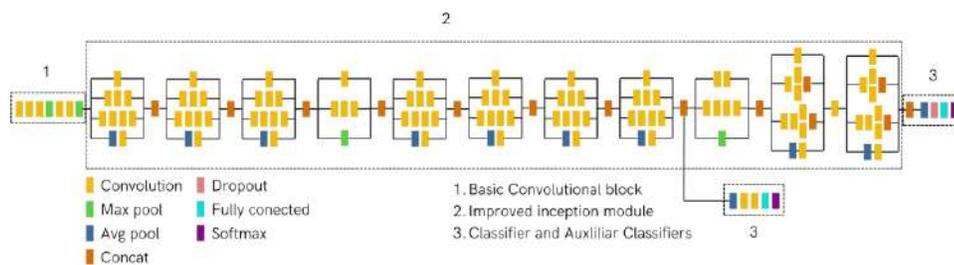


Figure 4. High level diagram of Inception V3.

The inception V3 network consists of ReLU activation functions which can remove the back propagation vanishing gradient problem during training and reduce the training time [40]. The equation of this function is shown below.

$$y = \max(0, x) \tag{2}$$

Once the CNN architecture has been established, the Transfer Learning technique will be applied, which is a tool already validated by the scientific community and presented by Tan et al. [41], which allows us to reduce the time and computational cost for training the classification model of helmet use in motorcyclists, which is usually very high when training a deep learning model from scratch. This technique tries to transfer the learning from one

domain to another domain, which is categorized into four groups, among which is network-based, in which it refers to the partial reuse of a pre-trained network in a certain domain, which includes the structure and connection parameters as shown in Figure 5.

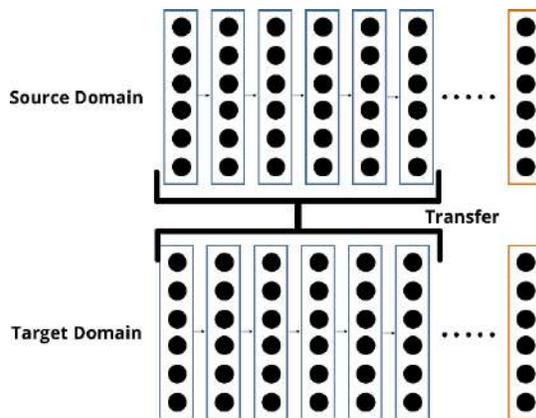


Figure 5. Sketch map of network-based deep transfer learning.

As mentioned in the above definition, partial reuse of the network means that for the experiment the last layer will be modified to obtain two possible output results (with helmet and without helmet) through sigmoid Equation (3), where the input is any value between negative infinity and positive infinity number and the output can only have values between zero and one.

$$\Phi(z) = \frac{1}{1 + e^{-z}} \tag{3}$$

This last layer will be trained by back propagation algorithm, which can be broken down into four steps: (1) Feed-forward computation, (2) Back propagation to the output layer, (3) Back propagation to the hidden layer, (4) Weight updates [42]. The adjust of weight parameter will use the cross-entropy cost function, where the error between the given output of the last layer and the real value of the given example is calculated. The Formula of cross-entropy loss is shown in the Equation (4),

$$Crossentropy = -[x \log(y) + (1 - x) \log(1 - y)] \tag{4}$$

where “x” is the actual value and “y” is the predicted value. For this experimentation, Tensorflow’s Adam optimizer will be used with a learning rate of 0.01. This is an algorithm for first-order gradient-based optimization of stochastic objective functions, which is based on adaptive estimates of lower-order moments, and generally performs well in situations where problems address large amounts of data or parameters [43]. For each training epoch, a batch size of 200 images sufficient to improve model performance was handled. The retraining script will output a “.pb” file with the new modified classification model, and a “.txt” file containing the new classes (“with helmet” and “without helmet”). Both files are in a format that Python can read. This part of the InceptionV3 retraining is based on the work published by Tensorflow [44].

In the test phase a new script will use the re-trained model to generate helmet usage predictions on the set of test images, and five different metrics: accuracy, sensitivity, specificity, Area Under the Curve (AUC) and Precision will measure the performance of the model detecting helmeted and unhelmeted drivers. All this evaluation metrics are based on a table called Confusion matrix, where the rows represents the actual values, and the columns the predicted values [45]. An example of two-class confusion matrix is shown in Figure 6.

		Predicted Class	
		Actual Class	Actual Class
True Class	Actual Class	TP	FN
	Actual Class	FP	TN

Figure 6. A two-class Confusion matrix.

TN refers to true negative results, TP to true positive results, FN refers to false negative results, and FP is the abbreviation of false positive results. The Accuracy metric is the ratio of the number of true results between the total number of samples, this is shown in Equation (5):

$$Accuracy = \frac{TN + TP}{TN + FN + TP + FP} \tag{5}$$

The sensitivity metric is the ratio of the total positive samples that are correctly classified as positive and the specificity is the proportion of negative samples that are correctly classified as negative [46].

$$Sensitivity = \frac{TP}{TP + FN} \tag{6}$$

$$Specificity = \frac{TN}{TN + FP} \tag{7}$$

The metric Area Under the Curve (AUC) is the area under the Receiver Operating Characteristic (ROC) curve, that is a graphical representation of the performance of a classifier. The AUC can have values between 0 and 1, where values close to one indicate that the classifier performs well [45]. To calculate the AUC is through trapezoidal integration [47], shown in Equation (7).

$$AUC = \sum_i (1 - \beta_i \cdot \Delta\alpha) + \frac{1}{2} [\Delta(1 - \beta) \cdot \Delta\alpha] \tag{8}$$

where $\Delta(1 - \beta) = (1 - \beta_i) - (1 - \beta_{i-1})$ and $\Delta\alpha = \alpha_i + \alpha_{i-1}$.

The last evaluation criteria is the Precision presented in Equation (9).

$$Precision = \frac{TP}{TP + FP} \tag{9}$$

The pseudo code corresponding to this model testing stage is presented below.

Pseudo code for test the model.

```
#import the necessary libraries
#get the path of the model and the labels
#load the label file
#load the graph file
#loads the paths and class of the images contained in the test set #save the paths in
```

```

the variable "paths"
#save the class in the variable "realout"
#get the size of the test set rows=paths.size
#create an empty vector for save the paths of the incorrect predictions
pathsinc=[]
#creates a size vector of the test set for the predictions
predictout=np.zeros(rows,dtype=int)
#initializes "i" to control the position of the predictions.
i=0
#start a session for running TensorFlow operations.
with tf.Session() as sess:
    #get the last tensor of the model
    #start a loop that runs until there are no more images to load
    while(i<rows):
        #get the path
        #prepares the image for model input
        #make the prediction
        #classifies the prediction to class 0 or 1
        if ((predictions[0][0] > predictions[0][1])):
            With helmeth predictout[i]=1
        if ((predictions[0][1] > predictions[0][0])):
            Without helmet predictout[i]=0
        #print the prediction class and the real class for visualize how its working the model
        print("prediction # ",i, " ",predictout[i]," || ", realout[i])
        #if the prediction is incorrect save the path of the image in the vector pathsi
        if(predictout[i]!= realout[i]):
            pathsinc.append(paths[i])
            #update the variable i
            i=i+1
    #export the predictions
    #export the paths of the errors
    #Calculate the metrics

```

3. Results

This section presents the experimental results obtained according to the different 3 phases of the proposed methodology.

3.1. Results of Data Acquisition

In this phase, 32 videos were collected where each of the 16 drivers participated in two recordings, one with a helmet and the other without using it, resulting in a balanced database between the two classes. These videos lasted approximately two minutes, and were saved in mp4 format with the aforementioned configuration, it is worth mentioning that the videos were recorded in spaces for vehicle parking, both in the facilities of the Autonomous University of Zacatecas and residents of, Zacatecas, Mexico. Nine participants used full face type helmets and the remaining seven used the modular or flip-up type helmet. The study tests were carried out with the motorcycle without movement or static in order to provide greater safety to the study subjects. Also, participants were asked to simulate normal riding and different head movements to strengthen the data set for different rider positions. Figure 7 shows an example of the collected videos categorized



Figure 7. Example of collected videos.

3.2 Results of Data Pre-Processing

Four frames of the thirty available were extracted in each second of the recordings. With the execution of a developed script, each of these images is moved to a directory depending on its class. All the images was named with the participant number, the code “cc” for person with helmet and “sc” for person without helmet, and also the exact time of the recording corresponding to the extracted frame; the dimensions of the images remain 1920 by 1080 pixels. In total, 7465 images of people with helmets and 7680 for people without helmets were obtained, which adding these two figures gives us a result of 15,145 images. Of this total, we use 70% for the training model phase and 30% for the test phase. The following Table 3 shows the distribution of these new generated sets.

Table 3. Training and testing sets.

Class	Training Set (70%)	Test Set (30%)
C0: Without Helmet	5376	2304
C1: With Helmet	5226	2239
Total	10,602	4543

3.3 Results of Model Generation and Validation

Two models were trained with the set of 10,602 images, varying the number of epochs, specifically 500 and 2000 respectively. In this phase, the accuracy of the model and the cross-entropy were monitored every 10 epochs. As can be seen in Figure 8, the performance of both models is satisfactory, since the loss of the validation is higher than the loss in the training process [48].

The Figure 9A, present the confusion matrix obtained through the classification of helmeted and unhelmeted motorcyclist using the model one trained by 500 epochs in the test set, and the Figure 9B, shows the confusion matrix corresponding to the results obtained from the classification using the model two trained by 2000 epochs. It is easy to see which in the first confusion matrix, a total of 4209 images, equivalent to 92.64% of the set of test images, were correctly categorized; 1987 of study subjects without helmets and 2222 with helmets. In

the case of the second confusion matrix, a total of 4418 images were correctly classified, equivalent to 97.24% of the test set; 2187 from study subjects without helmets and the remaining 2231 with helmets.

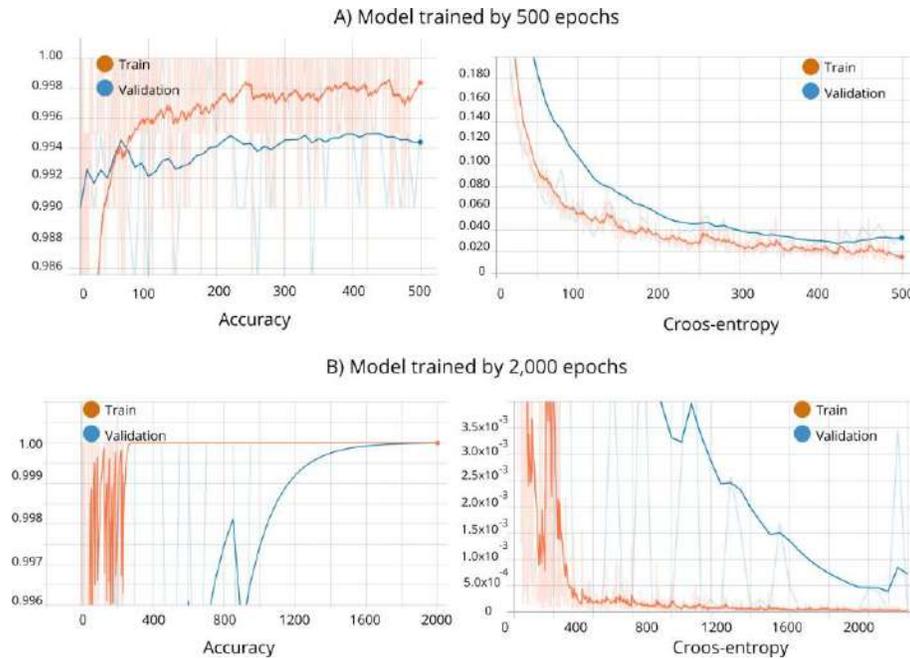


Figure 8. Accuracy and cross-entropy monitoring in the model training stage.

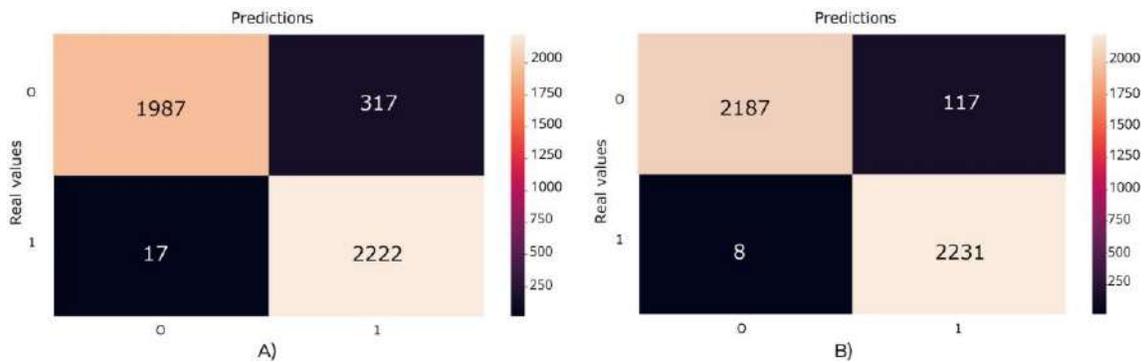


Figure 9. (A) Confusion matrix corresponding to Model 1 test (trained by 500 epochs). (B) Confusion matrix corresponding to Model 2 test (trained by 2000 epochs).

In Figure 10 shows the two ROC curves resulting from testing the aforementioned models on the test set, the line blue shows the relation between the sensitivity and the specificity of each model. The red line shows what the result would be like if the model were very poor in classification. The respective AUC values are: 0.9274 for the first model and 0.9728 for the second.

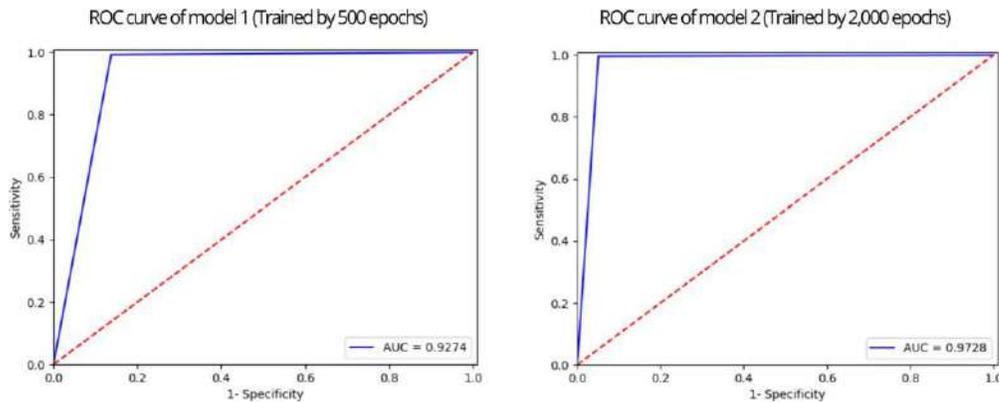


Figure 10. ROC curves.

Table 4 presents the Accuracy, Sensitivity and Specificity metrics resulting from the evaluations of the models using the test set.

Table 4. Accuracy, Sensitivity, Specificity and Precision in the test set obtained by model.

	Accuracy	Sensitivity	Specificity	Precision
Model 1	0.9264	0.8624	0.9924	0.9915
Model 2	0.9724	0.9492	0.9964	0.9963

These results show that thanks to the proposed methodology it is possible to detect in an objective and satisfactory manner the adequate use of the helmet in real time, since the validation rates obtained from different metrics prove it, and having the best performance model 2 trained for 2000 epochs.

4. Discussion

Table 5 shows the results obtained in the literature by different research proposals where different convolutional neural networks are used as a method of helmet detection and a comparison is made with the best model established in this work. As can be seen the accuracy rates are similar in most of the works presented, however the author Singh et al. [17], shows a greater difference in classification with respect to the others, this is because the accuracy rate only refers to that obtained in the training process of the model and in the proposal refers to the performance of the model in the testing stage where images that the model has never seen are used to classify them, this means that the neural network used has a better understanding to generalize between the different categories established (with helmet and without helmet). In the case of Rohith et al. [19], in spite of using a training methodology of an inception V3 convolutional neural network, the number of images from train and test the model is much smaller, which causes a drop in performance. On the other hand, the case of the Shine et al. [20] presents an excellent performance using a segmentation process for the initial identification of the motorcycle and then the detection of the helmet, their disadvantage is since its work involves the system being fixed in strategic areas, it runs the risk of being violated in different like: avoiding the monitoring area, using the helmet only in those surveillance areas, and in addition to the fact that monitoring is not constant throughout the driver’s journey, finally, the test set of their model is 33% smaller than our proposal, which can affect the results of the validation metrics. An important advantage of using pre-trained models is that they

have the ability to obtain good results if the experimentation scenario changes, however, using a custom network in another scenario can bring different results to those previously obtained. In the work presented by Lin et al. [21], who uses the Inceptionv3 architecture together with the Multi Transfer Learning technique, the accuracy is lower because the proposal classifies the use of the helmet in all the occupants of the motorcycle and not only in the driver, which makes this a multi-class problem. In the case of Cheng et al. [22], we can see that the accuracy of the model is clearly affected by the small amount of data available to train and validate the model. According to the results mentioned by Jia et al. [23], the YOLO series algorithms are a viable option to identify helmet use in images where the number of elements present is varied, as it is in the case of urban traffic images. Finally, Waris et al. [24] report metrics very similar to that achieved by our proposal, with the difference that 200,000 training epochs were needed to train their model to reach their best result.

With the comparison presented we can see that this work in our first approach shows to have strong points as shown by the values of the evaluation metrics. The big difference that our work has with the proposals that currently exist is that it is planned so that in the future it will be part of a preventive system that is part of the motorcycle, it will be able to detect the use of the helmet in real time, thus having a preventive safety method with a high confidence index that helps prevent serious and even fatal head injuries by ensuring that the motorcyclist is wearing his helmet.

Table 5. Comparison of results between related works and our proposed work by classification of helmeted and unhelmeted motorcyclists.

	Model Used	Video Resolution	Accuracy	Sensitivity or Recall	Specificity	AUC	Precision
Our proposed work	Retrained Inception V3	1920*1080	0.9724	0.9492	0.9964	0.9728	0.9963
* Singh et al. [17]	Custom CNN	N/M	0.991	N/M	N/M	N/M	N/M
Rohit et al. [19]	Retrained Inception V3	1920*1088	0.74	N/M	N/M	N/M	N/M
Shine et al. [20]	Custom CNN	1250*720	0.9962	1	N/M	1	1
Lin et al. [21]	Retrained Inception V3	1920*1080	0.806	N/M	N/M	N/M	N/M
Cheng et al. [22]	SAS-YOLOv3-tiny	N/M	0.782	0.809	N/M	N/M	0.716
Jia et al. [23]	YOLOv5-HD	1920*1080	N/M	0.972	N/M	N/M	0.98
Waris et al. [24]	Faster R-CNN	N/M	0.9769	0.9825	0.9694	N/M	0.9770

N/M: the research does not mention the result obtained. *: Results obtained only in the training stage of the model.

To end this discussion, it is a fact that to date there are different researches that seek to improve the road safety of motorcyclist users, however the literature shows that these helmet detection systems focus on fixed video security methods that can be easily circumvented, which ultimately seek to be corrective systems for the action of helmet use and do not ensure that the motorcyclist uses this protective element throughout the journey.

5. Conclusions

In conclusion, it can be said that the research and experimentation work carried out in this article provides a first approach to the generation of new preventive safety systems that guarantee the use of the helmet from the moment the motorcyclist begins his journey until the end of it, based on the fact that such preventive systems become part of the motorcycle and thus really take advantage of the real-time detection of the helmet. In addition, this new motorcycle safety approach of monitoring helmet use from a position on the motorcycle has not been studied based on the literature review conducted in this research. It has been shown that intelligent models that are generated with deep learning algorithms such as CNNs are capable of identifying in real time the absence of essential elements for your safety, such as a helmet, with an accuracy of 97.24%, which means that it presents highly satisfactory results in relation

to some of the related works. However, the previously proposed models suggest their implementation in fixed areas, which implies different forms of violation of the surveillance systems of responsible helmet use for the safety of motorcyclists, in addition to the fact that such proposals have the disadvantage that in order to comply with the aim of increase helmet use, they must work in conjunction with other systems, for example databases of registered motorcycles, and not directly with the motorcycle or the driver. Besides, it can be concluded that the amount of data and the tools necessary for its processing must be directly related to obtain good results, in this first approximation of our work where data collection has been limited was a good choice decided to use the transfer learning for improve the performance of the model.

Future Work

Although this proposal seeks to improve the safety of motorcyclists and reduce the rate of road accidents caused by these means of transport, there is still much work to be done, which is why the following points are proposed as future work.

Reinforce the set of training images with different elements that may confuse the model, increasing the number of test subjects in the experimental phase, thus strengthening the helmet detection model in different situations such as the environment or elements within the area of interest that could hinder the classification process. On the other hand, it should be noted that this work is established as a first approximation for real-time helmet detection in motorcyclists, since specialists in the field of safety and development of intelligent models based on deep learning suggest a larger number of study subjects that can help to improve the classification models.

Another work proposal, is to compare different CNN architectures in the classification of helmet use, for example the Wearnnet proposed by Li et al. [49], which has had outstanding advantages in terms of classification speed and ideal model size for applications working in real time, or to test with the architectures used in the related works mentioned above that had satisfactory results in the classification task.

Author Contributions: Conceptualization, J.M.R., J.M.C.-P. and C.H.E.-S.; methodology, J.M.R., H.L.-G. and C.E.G.-T.; software, J.M.R. and R.S.R.; validation, J.I.G.-T., H.G.-R. and J.M.C.-P.; formal analysis, J.M.R. and J.I.G.-T.; investigation, J.M.R., H.L.-G. and J.M.C.-P.; resources, D.R. and K.O.V.-C.; writing—original draft preparation, J.M.R. and C.H.E.-S.; writing—review and editing, J.M.R., J.M.C.-P. and R.S.R.; supervision, D.R. and K.O.V.-C.; project administration, H.L.-G. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding. **Institutional**

Review Board Statement: Not applicable. **Informed Consent**

Statement: Not applicable.

Data Availability Statement: Not applicable.

Acknowledgments: CONACYT and H.A. Ojocaliente Zacatecas for supporting the author Jaime Mercado Reyna.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Cadavid, L.; Salazar-Serna, K. Mapping the Research Landscape for the Motorcycle Market Policies: Sustainability as a Trend—A Systematic Literature Review. *Sustainability* **2021**, *13*, 10813. [CrossRef]
2. Jittrapirom, P.; Knoflacher, H.; Mailer, M. The conundrum of the motorcycle in the mix of sustainable urban transport. *Transp. Res. Procedia* **2017**, *25*, 4869–4890. [CrossRef]

3. Abdi, N.; Robertson, T.; Petrucka, P.; Crizzle, A.M. Do motorcycle helmets reduce road traffic injuries, hospitalizations and mortalities in low and lower-middle income countries in Africa? A systematic review and meta-analysis. *BMC Public Health* **2021**, *22*, 824. [[CrossRef](#)]
4. Cheng, A.S.; Liu, K.P.; Tulliani, N. Relationship Between Driving-violation Behaviours and Risk Perception in Motorcycle Accidents. *Hong Kong J. Occup. Ther.* **2015**, *25*, 32–38. [[CrossRef](#)]
5. MacLeod, J.B.; Digiacomio, J.C.; Tinkoff, G. An evidence-based review: Helmet efficacy to reduce head injury and mortality in motorcycle crashes: EAST practice management guidelines. *J. Trauma-INJ Infect. Crit. Care* **2010**, *69*, 1101–1111. [[CrossRef](#)]
6. World Health Organization. *Powered Two-and Three-Wheeler Safety: A Road Safety Manual For Decision-Makers and Practitioners*; World Health Organization: Geneva, Switzerland, 2017.
7. WHO. *Global Status Report on Road on Road Safety*; WHO: Geneva, Switzerland, 2018.
8. Tabary, M.; Ahmadi, S.; Amirzade-Iranaq, M.H.; Shojaei, M.; Asl, M.S.; Ghodsi, Z.; Azarhomayoun, A.; Ansari-Moghaddam, A.; Atlasi, R.; Araghi, F.; et al. The effectiveness of different types of motorcycle helmets—A scoping review. *Accid. Anal. Prev.* **2021**, *154*, 106065. [[CrossRef](#)] [[PubMed](#)]
9. Sharif, P.M.; Pazooki, S.N.; Ghodsi, Z.; Nouri, A.; Ghoroghchi, H.A.; Tabrizi, R.; Shafieian, M.; Heydari, S.T.; Atlasi, R.; Sharif-Alhoseini, M.; et al. Effective factors of improved helmet use in motorcyclists: A systematic review. *BMC Public Health* **2023**, *23*, 26. [[CrossRef](#)]
10. Araujo, M.; Illanes, E.; Chapman, E.; Rodrigues, E. Effectiveness of interventions to prevent motorcycle injuries: Systematic review of the literature. *Int. J. INJ Control. Saf. Promot.* **2017**, *24*, 406–422. [[CrossRef](#)]
11. WHO. *WHO Kicks off a Decade of Action for Road Safety*; WHO: Geneva, Switzerland, 2021.
12. WHO. *Helmets: A Road Safety Manual for Decision-makers and Practitioners*; WHO Library Cataloguing in Publication Data; WHO: Geneva, Switzerland, 2006; pp. 1–147.
13. Craft, G.; Bui, T.V.; Sidik, M.; Moore, D.; Ederer, D.J.; Parker, E.M.; Ballesteros, M.F.; Sleet, D.A. A Comprehensive Approach to Motorcycle-Related Head Injury Prevention: Experiences from the Field in Vietnam, Cambodia, and Uganda. *Int. J. Environ. Res. Public Health* **2017**, *14*, 1486. [[CrossRef](#)]
14. Forum, I.T. Improving Motorcyclist Safety: Priority actions for Safe System Integration. Available online: <https://www.itf-oecd.org/improving-motorcyclist-safety> (accessed on 3 March 2023).
15. Ambak, K.; Rahmat, R.; Ismail, R. Intelligent Transport System for Motorcycle Safety and Issues. *Eur. J. Sci. Res.* **2009**, *28*, 600–611.
16. Forero, M.A.V. Detection of motorcycles and use of safety helmets with an algorithm using image processing techniques and artificial intelligence models. In Proceedings of the MOVICI-MOYCOT 2018: Joint Conference for Urban Mobility in the Smart City, Medellin, Colombia, 18–20 April 2018; pp. 1–9. [[CrossRef](#)]
17. Singh, A.; Singh, D.; Singh, J.; Singh, P.; Kaur, D.A. Helmet & Number Plate Detection Using Deep Learning and Its Comparative Analysis. In Proceedings of the International Conference on Innovative Computing & Communication (ICICC) 2022, Delhi, India, 19–20 February 2022.
18. Goyal, A.; Agarwal, D.; Subramanian, A.; Jawahar, C.V.; Sarvadevabhatla, R.K. Detecting, Tracking and Counting Motorcycle Rider Traffic Violations on Unconstrained Roads. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, New Orleans, LA, USA, 18–24 June 2022.
19. Rohith, C.A.; Nair, S.A.; Nair, P.S.; Alphonsa, S.; John, N.P. An efficient helmet detection for MVD using deep learning. In Proceedings of the International Conference on Trends in Electronics and Informatics, ICOEI 2019, Tirunelveli, India, 23–25 April 2019; pp. 282–286. [[CrossRef](#)]
20. Shine, L.; Jiji, C.V. Automated detection of helmet on motorcyclists from traffic surveillance videos: A comparative analysis using hand-crafted features and CNN. *Multimed. Tools Appl.* **2020**, *79*, 14179–14199. [[CrossRef](#)]
21. Lin, H.; Deng, J.D.; Albers, D.; Siebert, F.W. Helmet Use Detection of Tracked Motorcycles Using CNN-Based Multi-Task Learning. *IEEE Access* **2020**, *8*, 162073–162084. [[CrossRef](#)]
22. Cheng, R.; He, X.; Zheng, Z.; Wang, Z. Multi-Scale Safety Helmet Detection Based on SAS-YOLOv3-Tiny. *Appl. Sci.* **2021**, *11*, 3652. [[CrossRef](#)]
23. Jia, W.; Xu, S.; Liang, Z.; Zhao, Y.; Min, H.; Li, S.; Yu, Y. Real-time automatic helmet detection of motorcyclists in urban traffic using improved YOLOv5 detector. *IET Image Process.* **2021**, *15*, 3623–3637. [[CrossRef](#)]
24. Waris, T.; Asif, M.; Ahmad, M.B.; Mahmood, T.; Zafar, S.; Shah, M.; Ayaz, A. CNN-Based Automatic Helmet Violation Detection of Motorcyclists for an Intelligent Transportation System. *Math. Probl. Eng.* **2022**, *2022*, 8246776. [[CrossRef](#)]
25. Rasli, M.K.A.M.; Madzhi, N.K.; Johari, J. Smart Helmet with Sensors for Accident Prevention. In Proceedings of the 2013 International Conference on Electrical, Electronics and System Engineering (ICEESE), Selangor, Malaysia, 4–5 December 2013; pp. 21–26.

26. Kashevnik, A.; Ali, A.; Lashkov, I.; Shilov, N. Seat Belt Fastness Detection Based on Image Analysis from Vehicle In-cabin Camera. In Proceedings of the 2020 26th Conference of Open Innovations Association (FRUCT), Yaroslavl, Russia, 20–24 April 2020; pp. 143–150. [CrossRef]
27. Sampieri, R.H. *Fundamentos de Investigacion*; McGraw-Hill/Interamericana: New York, NY, USA, 2017.
28. LeCun, Y.; Bengio, Y.; Hinton, G. Deep learning. *Nature* **2015**, *521*, 436–444. [CrossRef]
29. Team MCD. Mexico 2022. Motorcycles Market Hits The 9th Record in A String. Available online: <https://www.motorcyclesdata.com/2023/02/03/mexico-motorcycles/> (accessed on 15 March 2023).
30. Data Mexico. Conductores de Motocicleta: Salarios, Diversidad, Industrias e Informalidad Laboral. Available online: <https://datamexico.org/es/profile/occupation/conductores-de-motocicleta> (accessed on 28 April 2023).
31. Padway, M. Motorcycle Accident Statistics Updated to 2023-MLF Blog. 2023. Available online: <https://www.motorcyclelegalfoundation.com/motorcycle-accident-statistics-safety/> (accessed on 2 March 2023).
32. Kluyver, T.; Ragan-Kelley, B.; Pérez, F.; Granger, B.; Bussonnier, M.; Frederic, J.; Kelley, K.; Hamrick, J.; Grout, J.; Corlay, S.; et al. Jupyter Notebooks—A publishing format for reproducible computational workflows. In *Positioning and Power in Academic Publishing: Players, Agents and Agendas*; Loizides, F., Schmidt, B., Eds.; IOS Press: Amsterdam, The Netherlands, 2016; pp. 87–90.
33. Gholamy, A.; Kreinovich, V.; Kosheleva, O. A Pedagogical Explanation A Pedagogical Explanation Part of the Computer Sciences Commons. Available online: https://scholarworks.utep.edu/cgi/viewcontent.cgi?article=2202&context=cs_techrep (accessed on 23 March 2023).
34. Albawi, S.; Mohammed, T.A.; Al-Zawi, S. Understanding of a convolutional neural network. In Proceedings of the 2017 International Conference on Engineering and Technology, ICET 2017, Antalya, Turkey, 21–23 August 2017; pp. 1–6. [CrossRef]
35. Kuo, C.C.J. Understanding Convolutional Neural Networks with A Mathematical Model. *arXiv* **2016**, arXiv:1609.04112.
36. Lin, C.; Li, L.; Luo, W.; Wang, K.; Guo, J. Transfer Learning Based Traffic Sign Recognition Using Inception-v3 Model. *Period. Polytech. Transp. Eng.* **2018**, *47*, 242–249. [CrossRef]
37. Abadi, M.; Agarwal, A.; Barham, P.; Brevdo, E.; Chen, Z.; Citro, C.; Corrado, G.S.; Davis, A.; Dean, J.; Devin, M.; et al. TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems. *arXiv* **2016**. [CrossRef]
38. Guía avanzada de Inception v3[Cloud TPU]Google Cloud. Available online: <https://cloud.google.com/tpu/docs/inception-v3-advanced?hl=es-419> (accessed on 7 March 2023).
39. Szegedy, C.; Vanhoucke, V.; Ioffe, S.; Shlens, J.; Wojna, Z. Rethinking the Inception Architecture for Computer Vision. In Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 27–30 June 2016; pp. 2818–2826. [CrossRef]
40. Nair, V.; Hinton, G.E. Rectified linear units improve Restricted Boltzmann machines. In Proceedings of the ICML 2010-Proceedings, 27th International Conference on Machine Learning, Haifa, Israel, 21–24 June 2010.
41. Chuanqi, T.; Sun, F.; Tao, K.; Wenchang, Z.; Chao, Y.; Chunfang, L. *A Survey on Deep Transfer Learning*; Springer International Publishing: Cham, Switzerland, 2018; pp. 270–279.
42. Cilimkovic, M. Neural Networks and Back Propagation Algorithm. Available online: https://drive.uqu.edu.sa/_takawady/files/NeuralNetworks.pdf (accessed on 21 March 2023).
43. Kingma, D.P.; Ba, J.L. Adam: A Method for Stochastic Optimization. *arXiv* **2015**, arXiv:1412.6980.
44. How to Retrain an Image Classifier for New Categories|TensorFlow. Available online: https://web.archive.org/web/20180703133602/https://www.tensorflow.org/tutorials/image_retraining (accessed on 20 October 2022).
45. Özbilgin, F.; Kurnaz, Ç.; Aydın, E. Prediction of Coronary Artery Disease Using Machine Learning Techniques with Iris Analysis. *Diagnostics* **2023**, *13*, 1081. [CrossRef] [PubMed]
46. Banaei, N.; Moshfegh, J.; Mohseni-Kabir, A.; Houghton, J.M.; Sun, Y.; Kim, B. Machine learning algorithms enhance the specificity of cancer biomarker detection using SERS-based immunoassays in microfluidic chips. *RSC Adv.* **2019**, *9*, 1859–1868. [CrossRef] [PubMed]
47. Bradley, A.P. The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern Recognit.* **1997**, *30*, 1145–1159. . [CrossRef]
48. Pathar, R.; Adivarekar, A.; Mishra, A.; Deshmukh, A. Human Emotion Recognition using Convolutional Neural Network in Real Time. In Proceedings of the 2019 1st International Conference on Innovations in Information and Communication Technology (ICIICT), Chennai, India, 25–26 April 2019; pp. 1–7. [CrossRef]
49. Li, W.; Zhang, L.; Wu, C.; Cui, Z.; Niu, C. A new lightweight deep neural network for surface scratch detection. *Int. J. Adv. Manuf. Technol.* **2022**, *123*, 1999–2015. [CrossRef] [PubMed]

Disclaimer/Publisher’s Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.

Capítulo 4. Conclusiones

Esta propuesta la cual es la primera aproximación para la generación de nuevos sistemas preventivos del uso del casco en los motociclistas ha alcanzado los objetivos específicos planteados al inicio de la investigación y como resultado el objetivo general con lo que se afirma la hipótesis planteada.

En la etapa 1 al analizar el estado del arte acerca del tema de interés, se observó que de manera general la seguridad en la motocicleta es un tópico de reciente interés, esto debido al gran crecimiento en el uso de este tipo de transporte, la mayoría de los estudios publicados se centran en mejorar el uso del casco en los motociclistas. Esto en conjunto con la Inteligencia Artificial, específicamente el campo del aprendizaje profundo, ha resultado en propuestas innovadoras donde la mayoría se centran en generar Sistemas de Transporte Inteligente “correctivos” que, aunque detectan con gran precisión el uso del casco en el motociclista y en algunos casos los pasajeros, no corrigen la acción del uso del casco en tiempo real lo que resulta que los motociclistas y sus acompañantes sigan sin usar el casco en todo el trayecto.

Aspectos importantes que resultaron al analizar el punto de la generación de la base de datos son los siguientes; primero, existen variantes que pueden afectar significativamente la información presente en las imágenes cómo lo son, el clima, la cantidad de luz, objetos que aparecen en el fondo de la imagen, etc. Otro punto que afecta a la base de datos es la cantidad de personas que participan en el experimento, y los artículos personales como gorras, lentes o cubrebocas que utilizan los usuarios en el momento de la recolección de los datos. Ahora, de igual forma analizando la parte de la generación de modelo inteligente, en el cual se utilizó en conjunto las redes neuronales convolucionales y la transferencia de aprendizaje como principales herramientas o técnicas, se concluye que la red inceptionV3 ha presentado excelentes resultados que en cuanto a la precisión de clasificación de las imágenes superan en gran parte a varios de los trabajos relacionados mencionados anteriormente. Además, la técnica de transferencia de aprendizaje permite ahorrar tiempo de entrenamiento y así enfocar esfuerzos en otros puntos de la investigación. Como trabajo futuro se plantea robustecer la base de datos aplicando técnicas de aumento de datos además de incorporar una mayor cantidad de participantes al experimento, y en un futuro hacer pruebas de campo con el modelo montado en un sistema computacional de bajo costo.

Referencias

1. Abdi, N., Robertson, T., Petrucka, P., & Crizzle, A. M. (2021). Do motorcycle helmets reduce road traffic injuries, hospitalizations and mortalities in low and lower-middle income countries in Africa? A systematic review and meta-analysis. *BMC Public Health*. <https://doi.org/10.1186/s12889-022-13138-4>
2. Aboah, A., Wang, B., Bagci, U., & Adu-Gyamfi, Y. (2023). *Real-time Multi-Class Helmet Violation Detection Using Few-Shot Data Sampling Technique and YOLOv8*. <https://github.com/aboah1994/few-shot->
3. *Activation Functions: Sigmoid vs Tanh.* (2023). <https://www.baeldung.com/cs/sigmoid-vs-tanh-functions>
4. Akbari, M., Lankarani, K. B., Tabrizi, R., Vali, M., Heydari, S. T., Motevalian, S. A., & Sullman, M. J. M. (2021). The effect of motorcycle safety campaign on helmet use: A systematic review and meta-analysis. *IATSS Research*, 45(4), 513–520. <https://doi.org/10.1016/J.IATSSR.2021.06.001>
5. Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2018). Understanding of a convolutional neural network. *Proceedings of 2017 International Conference on Engineering and Technology, ICET 2017, 2018-January*, 1–6. <https://doi.org/10.1109/ICENGTECHNOL.2017.8308186>
6. Ali, A., Malik, M. A., Khan, U. R., Khudadad, U., Raheem, A., & Hyder, A. A. (2021). Helmet wearing saves the cost of motorcycle head injuries: A case study from Karachi, Pakistan. *ClinicoEconomics and Outcomes Research*, 13, 573–581. <https://doi.org/10.2147/CEOR.S297032>
7. Ambak, K., Rahmat, R., & Ismail, R. (2009). Intelligent Transport System for Motorcycle Safety and Issues. *Eur J Sci Res*, 28.
8. Araujo, M., Illanes, E., Chapman, E., & Rodrigues, E. (2017). Effectiveness of interventions to prevent motorcycle injuries: systematic review of the literature. *International Journal of Injury Control and Safety Promotion*, 24(3), 406–422. <https://doi.org/10.1080/17457300.2016.1224901>
9. Basha, S. H. S., Dubey, S. R., Pulabaigari, V., & Mukherjee, S. (2020). Impact of fully

- connected layers on performance of convolutional neural networks for image classification. *Neurocomputing*, 378, 112–119. <https://doi.org/10.1016/J.NEUCOM.2019.10.008>
10. Bewley, A., Ge, Z., Ott, L., Ramos, F., & Upcroft, B. (2016). Simple online and realtime tracking. *Proceedings - International Conference on Image Processing, ICIP, 2016-August*, 3464–3468. <https://doi.org/10.1109/ICIP.2016.7533003>
 11. Cadavid, L., & Salazar-Serna, K. (2021). *Mapping the Research Landscape for the Motorcycle Market Policies: Sustainability as a Trend-A Systematic Literature Review*. <https://doi.org/10.3390/su131910813>
 12. Cano, J. E. G., & Oliva, E. J. D. (2007). Metodología para el análisis y la revisión crítica de artículos de investigación. *Innovar*, 17(29), 184–194. <https://revistas.unal.edu.co/index.php/innovar/article/view/19596>
 13. Chai, J., & Li, A. (2019). Deep Learning in Natural Language Processing: A State-of-the-Art Survey. *2019 International Conference on Machine Learning and Cybernetics (ICMLC)*, 2019-July, 1–6. <https://doi.org/10.1109/ICMLC48188.2019.8949185>
 14. Chai, J., Zeng, H., Li, A., & Ngai, E. W. T. (2021). Deep learning in computer vision: A critical review of emerging techniques and application scenarios. *Machine Learning with Applications*, 6, 100134. <https://doi.org/10.1016/J.MLWA.2021.100134>
 15. Cheng, A. S. K., Liu, K. P. Y., & Tulliani, N. (2015). Relationship Between Driving-violation Behaviours and Risk Perception in Motorcycle Accidents. *Hong Kong Journal of Occupational Therapy*, 25, 32–38. <https://doi.org/10.1016/J.HKJOT.2015.06.001>
 16. Chou, C. C., Yoh, K., Inoi, H., Yamaguchi, T., & Doi, K. (2022). Effectiveness evaluation on cross-sector collaborative education programs for traffic safety toward sustainable motorcycle culture in Vietnam. *IATSS Research*, 46(2), 258–268. <https://doi.org/10.1016/J.IATSSR.2022.01.001>
 17. Reglamento General De La Ley De Transporte, Tránsito Y Vialidad Del Estado De Zacatecas, (2017).
 18. Cui, S., Zhang, T., Sun, H., Zhou, X., Yu, W., Zhen, A., Wu, Q., & He, Z. (2023). *An Effective Motorcycle Helmet Object Detection Framework for Intelligent*

Traffic Safety.

19. Department of Economic and Social Affairs ONU. (2022). *United Nations. Ensure Healthy Lives and Promote Well-Being for All at All Ages.* <https://sdgs.un.org/goals/goal3>
20. Díaz, R. (2020). *The Machine Learners.* Métricas de Clasificación. <https://www.themachinelearners.com/metricas-de-clasificacion/>
21. Ding, B., Qian, H., & Zhou, J. (2018). Activation functions and their characteristics in deep neural networks. *Proceedings of the 30th Chinese Control and Decision Conference, CCDC 2018*, 1836–1841. <https://doi.org/10.1109/CCDC.2018.8407425>
22. *DOF - Diario Oficial de la Federación.* (2018). Norma Oficial Mexicana NOM-206-SCFI/SSA2-2018. https://www.dof.gob.mx/nota_detalle.php?codigo=5524337&fecha=29/05/2018#gsc.tab=0
23. Dubey, S. R., Singh, S. K., & Chaudhuri, B. B. (2022). Activation functions in deep learning: A comprehensive survey and benchmark. *Neurocomputing*, 503, 92–108. <https://doi.org/10.1016/j.neucom.2022.06.111>
24. Duong, N.-N., Tran, L. H., Pham, H.-J., Jeon, H.-H., Nguyen, H.-M., Jeon, T., Tran, H.-P., & Jeon, J. W. (2023). *Robust Automatic Motorcycle Helmet Violation Detection for an Intelligent Transportation System.*
25. Faduyile, F., Emiogun, F., Soyemi, S., Oyewole, O., Okeke, U., & Williams, O. (2017). Pattern of Injuries in Fatal Motorcycle Accidents Seen in Lagos State University Teaching Hospital: An Autopsy-Based Study. *Open Access Macedonian Journal of Medical Sciences*, 5(2), 112–116. <https://doi.org/10.3889/oamjms.2017.025>
26. Fernandes, F. A. O., & Alves De Sousa, R. J. (2013). Motorcycle helmets—A state of the art review. *Accident Analysis & Prevention*, 56, 1–21. <https://doi.org/10.1016/J.AAP.2013.03.011>
27. Flanigan, E., Blizzard, K., Rivadeneyra, A., Campbell, R., & Systematics, C. (2018). *Motorcycle Safety and Intelligent Transportation Systems Gap Analysis, Final Report.* <https://doi.org/10.21949/1503647>
28. Francis, F., Moshiro, C., Hans Yngve, B., & Hasselberg, M. (2021).

Investigation of road infrastructure and traffic density attributes at high-risk locations for motorcycle-related injuries using multiple correspondence and cluster analysis in urban Tanzania. *Https://Doi.Org/10.1080/17457300.2021.1930060*, 28(4), 428–438. <https://doi.org/10.1080/17457300.2021.1930060>

29. *Gobierno de México*. (2022, February 9). Seguridad Vial En México. <https://www.gob.mx/capufe/articulos/seguridad-vial-en-mexico>

30. Górriz, J. M., Ramírez, J., Ortíz, A., Martínez-Murcia, F. J., Segovia, F., Suckling, J., Leming, M., Zhang, Y. D., Álvarez-Sánchez, J. R., Bologna, G., Bonomini, P., Casado, F. E., Charte, D., Charte, F., Contreras, R., Cuesta-Infante, A., Duro, R. J., Fernández-Caballero, A., Fernández-Jover, E., ... Ferrández, J. M. (2020). Artificial intelligence within the interplay between natural and artificial computation: Advances in data science, trends and applications. *Neurocomputing*, 410, 237–270. <https://doi.org/10.1016/J.NEUCOM.2020.05.078>

31. Goyal, A., Agarwal, D., Subramanian, A., Jawahar, C. V., Sarvadevabhatla, R. K., & Saluja, R. (2022). Detecting, Tracking and Counting Motorcycle Rider Traffic Violations on Unconstrained Roads. *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2022-June*, 4302–4311. <https://doi.org/10.1109/CVPRW56347.2022.00476>

32. Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J., & Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern Recognition*, 77, 354–377. <https://doi.org/10.1016/J.PATCOG.2017.10.013>

33. Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M. S. (2016). Deep learning for visual understanding: A review. *Neurocomputing*, 187, 27–48. <https://doi.org/10.1016/J.NEUCOM.2015.09.116>

34. Hagen, J. X., Pardo, C. F., & Valente, J. B. (2016). Motivations for motorcycle use for Urban travel in Latin America: A qualitative study. *Transport Policy*, 49, 93–104. <https://doi.org/10.1016/J.TRANPOL.2016.04.010>

35. Hegazy, T., Fazio, P., & Moselhi, O. (1994). Developing Practical Neural Network Applications Using Back-Propagation. *Computer-Aided Civil and Infrastructure Engineering*, 9(2), 145–159. <https://doi.org/10.1111/J.1467->

8667.1994.TB00369.X

36. Hernández Sampieri, R. (2017). *Fundamentos de investigación*. McGraw-Hill/Interamericana.
37. Hounkpe Dos Santos, B., Glele Ahanhanzo, Y., Kpozehouen, A., Daddah, D., Lagarde, E., & Coppieters, Y. (2021). Effect of wearing a helmet on the occurrence of head injuries in motorcycle riders in Benin: a case-control study. *Injury Epidemiology*, 8(1), 1–11. <https://doi.org/10.1186/S40621-021-00311-3/TABLES/5>
38. Ian Goodfellow, Yoshua Bengio, and A. C. (2017). Deep ILearning. *Genetic Programming and Evolvable Machines*, 19(1–2), 305–307. https://books.google.com/books/about/Deep_Learning.html?id=Np9SDQAAQBAJ
39. *imagen | Diccionario de la lengua española (2001) | RAE - ASALE*. (2001). <https://www.rae.es/drae2001/imagen>
40. INEGI. (2021). *Accidentes de tránsito terrestre*. https://www.inegi.org.mx/sistemas/olap/proyectos/bd/continuas/transporte/accidentes.asp?s=est&c=13159&proy=atus_accidentes
41. INEGI. (2023). *Vehiculos Registrados*. https://www.inegi.org.mx/sistemas/olap/consulta/general_ver4/MDXQueryDatos.asp?#Regreso&c=13158
42. IRTAD. (2019). *ROAD SAFETY ANNUAL REPORT 2020*.
43. Jia, W., Xu, S., Liang, Z., Zhao, Y., Min, H., Li, S., & Yu, Y. (2021). Real-time automatic helmet detection of motorcyclists in urban traffic using improved YOLOv5 detector. *IET Image Processing*, 15(14), 3623–3637. <https://doi.org/10.1049/IPR2.12295>
44. Jittrapirom, P., Knoflacher, H., & Mailer, M. (2017). The conundrum of the motorcycle in the mix of sustainable urban transport. *Transportation Research Procedia*, 25, 4869–4890. <https://doi.org/10.1016/J.TRPRO.2017.05.365>
45. Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255–260. <https://doi.org/10.1126/science.aaa8415>
46. Khosroshahi, S., Ghajari, M., & Galvanetto, U. (2015, November). *Assessment of Motorcycle Helmet's Chin Bar Design Criteria with Respect to Basilar Skull Fracture*

Using FEM.

47. Kongwat, S., Nueanim, T., & Hasegawa, H. (2022). FE Analysis of Motorcycle Helmet Performance under Severe Accidents. *Applied Sciences*, 12(11). <https://doi.org/10.3390/app12115676>
48. LeCun, Y., Bengio, Y., & Hinton, G. (2015). *Deep learning*. <https://doi.org/10.1038/nature14539>
49. LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2323. <https://doi.org/10.1109/5.726791>
50. Ledesma, R. D. (2008). Helmet use among motorcyclists: observational study in the city of Mar del Plata, Argentina. *Rev Saúde Pública*, 42(1), 143–148.
51. Ley General de Movilidad y Seguridad Vial, (2022).
52. MacLeod, J. B. A., Digiacomio, J. C., & Tinkoff, G. (2010). An evidence-based review: Helmet efficacy to reduce head injury and mortality in motorcycle crashes: EAST practice management guidelines. *Journal of Trauma - Injury, Infection and Critical Care*, 69(5), 1101–1111. <https://doi.org/10.1097/TA.0B013E3181F8A9CC>
53. Madan, P., & Madhavan, S. (2020). *An introduction to deep learning - IBM Developer*. <https://developer.ibm.com/articles/an-introduction-to-deep-learning/>
54. Mahdavi Sharif, P., Naja Pazooki, S., Ghodsi, Z., Nouri, A., Abbasizade Ghoroghchi, H., Tabrizi, R., Shaeian, M., Taghi Heydari, S., Atlasi, R., Sharif-Alhoseini, M., & Ansari-Moghaddam, A. (2022). *Effective factors of improved helmet use in motorcyclists: a systematic review*. <https://doi.org/10.21203/rs.3.rs-1830051/v1>
55. Mahesh, B. (2018). Machine Learning Algorithms-A Review. *International Journal of Science and Research*. <https://doi.org/10.21275/ART20203995>
56. Mercado Reyna, J., Luna-Garcia, H., Espino-Salinas, C. H., Celaya-Padilla, J. M., Gamboa-Rosales, H., Galván-Tejada, J. I., Galván-Tejada, C. E., Solís Robles, R., Rondon, D., & Villalba-Condori, K. O. (2023). Detection of Helmet Use in Motorcycle Drivers Using Convolutional Neural Network. *Applied Sciences*, 13(10). <https://doi.org/10.3390/app13105882>
57. Mohd Rasli, M. K. A., Madzhi, N. K., & Johari, J. (2013). Smart Helmet with Sensors for Accident Prevention. *2013 International Conference on Electrical,*

Electronics and System Engineering (ICEESE), 21–26.

58. *motorcycle legal foundation*. (2021). A Beginner's Guide to Types of Motorcycle Helmets. <https://www.motorcyclelegalfoundation.com/types-of-motorcycle-helmets/>

59. MotorCycles Data. (2022). *MotorCycles Data*. Mexico Motorcycles Market - Facts & Data 2022 | MotorCyclesData. https://www.motorcyclesdata.com/2022/06/12/mexico-motorcycles/?_gl=1*jiagp6*_up*MQ.*_ga*MTIzNjYxMTg4NC4xNjY2NzIyMzEz*_ga_Q0PHN6Z2QT*MTY2NjcyMjMxMy4xLjEuMTY2NjcyMjM3Ny4wLjAuMA..

60. Nacional De Lanús, U., Tosi, A., David, J., Ledesma, :, Daniel, R., Poó, :, Martín, F., Montes, :, Andrea, S., López, :, & Susana, S. (2016). Prevalencia y evolución del uso de casco en ocupantes de motocicletas en una ciudad argentina (Mar del Plata, 2006-2014). *Salud Colectiva*, 12(1), 85–95. <https://doi.org/10.18294/sc.2016.679>

61. Naphade, M., Wang, S., Anastasiu, D. C., Tang, Z., Chang, M.-C., Yao, Y., Zheng, L., Rahman, M. S., Arya, M. S., Sharma, A., Feng, Q., Ablavsky, V., Sclaroff, S., Chakraborty, P., Prajapati, S., Li, A., Li, S., Kunadharaju, K., Jiang, S., & Chellappa, R. (2023). *The 7th AI City Challenge*.

62. Novoa, A. M., Pérez, K., & Borrell, C. (2009). [Evidence-based effectiveness of road safety interventions: a literature review]. *Gaceta Sanitaria*, 23(6). <https://doi.org/10.1016/J.GACETA.2009.04.006>

63. OMS. (2018). *GLOBAL STATUS REPORT ON ROAD SAFETY 2018*. <https://www.who.int/publications/i/item/9789241565684>

64. OMS. (2021). *Global Plan Decade Of Action For Road Safety 2021-2030*. https://cdn.who.int/media/docs/default-source/documents/health-topics/road-traffic-injuries/global-plan-for-road-safety.pdf?sfvrsn=65cf34c8_35&download=true

65. OMS. (2022a). *POWERED TWO-AND THREE-WHEELER SAFETY A road safety manual for decision-makers and practitioners*.

66. OMS. (2022b, June 20). *Traumatismos causados por el tránsito*. Traumatismos Causados Por El Tránsito. <https://www.who.int/es/news-room/fact-sheets/detail/road-traffic-injuries>

67. Ongsulee, P. (2017). Artificial intelligence, machine learning and deep

- learning. *2017 15th International Conference on ICT and Knowledge Engineering (ICT&KE)*, 1–6. <https://doi.org/10.1109/ICTKE.2017.8259629>
68. O'shea, K., & Nash, R. (2015). *An Introduction to Convolutional Neural Networks*.
69. Ouyang, J., Jang, Z., Cho, H., Zhou, X., & Krähenbühl, P. (2022). *NMS Strikes Back*. <https://github.com/jozhang97/DETA>.
70. Paleyes, A., & Lawrence, N. D. (2022). *Challenges in Deploying Machine Learning: A Survey of Case Studies*. <https://doi.org/10.1145/3533378>
71. Pan, S. J., & Yang, Q. (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345–1359. <https://doi.org/10.1109/TKDE.2009.191>
72. Parrotte, M. (2022). *Which Helmet Standard Is the Best?* <https://agvsport.com/blog/which-helmet-standard-is-the-best-snell-dot-ece-sharp-or-fim.html>
73. Petridou, E., & Moustaki, M. (2000). Human factors in the causation of road traffic crashes. *European Journal of Epidemiology* 2000 16:9, 16(9), 819–826. <https://doi.org/10.1023/A:1007649804201>
74. Rahim Khan, U., Razzak, J. A., Jooma, R., & Gerdin Wärnberg, M. (2022). Association of age and severe injury in young motorcycle riders: A cross-sectional study from Karachi, Pakistan. *Injury*, 53, 3019–3024. <https://doi.org/10.1016/j.injury.2022.04.017>
75. Riedl, M. O. (2019). Human-centered artificial intelligence and machine learning. *Human Behavior and Emerging Technologies*, 1(1), 33–36. <https://doi.org/https://doi.org/10.1002/hbe2.117>
76. Rohith, C. A., Nair, S. A., Nair, P. S., Alphonsa, S., & John, N. P. (2019). An efficient helmet detection for MVD using deep learning. *Proceedings of the International Conference on Trends in Electronics and Informatics, ICOEI 2019, 2019-April*, 282–286. <https://doi.org/10.1109/ICOEI.2019.8862543>
77. Saini, H. K., Chouhan, S. S., & Kathuria, A. (2022). Exclusive motorcycle lanes: A systematic review. *IATSS Research*, 46(3), 411–426. <https://doi.org/10.1016/J.IATSSR.2022.05.004>

78. Sharma, N., Sharma, R., & Jindal, N. (2021). Machine Learning and Deep Learning Applications-A Vision. *Global Transitions Proceedings*, 2(1), 24–28. <https://doi.org/10.1016/J.GLTP.2021.01.004>
79. Sharma, S., Sharma, S., & Athaiya, A. (2020). ACTIVATION FUNCTIONS IN NEURAL NETWORKS. *International Journal of Engineering Applied Sciences and Technology*, 4, 310–316. <http://www.ijeast.com>
80. Shuaeib, F. M., Hamouda, A. M. S., Hamdan, M. M., Radin Umar, R. S., & Hashmi, M. S. J. (2002). Motorcycle helmet: Part II. Materials and design issues. *Journal of Materials Processing Technology*, 123(3), 422–431. [https://doi.org/10.1016/S0924-0136\(02\)00047-X](https://doi.org/10.1016/S0924-0136(02)00047-X)
81. Siebert, F. W., & Lin, H. (2019). *Detecting motorcycle helmet use with deep learning*.
82. Singh, A., Singh, D., Singh, J., Singh, P., & Kaur, Dr. A. (2022). Helmet & Number Plate Detection Using Deep Learning and Its Comparative Analysis. *SSRN Electronic Journal*. <https://doi.org/10.2139/SSRN.4149145>
83. Sisimwo, P. K., & Onchiri, G. M. (2018). Epidemiology of head injuries and helmet use among motorcycle crash injury: a quantitative analysis from a local hospital in Western Kenya. *The Pan African Medical Journal*, 31. <https://doi.org/10.11604/PAMJ.2018.31.70.16988>
84. STCONAPRA. (2022a). *Informe sobre la Situación de la Seguridad Vial México 2020*.
85. STCONAPRA. (2022b). *Informe sobre la Situación de la Seguridad Vial México 2020*.
86. STCONAPRA. (2023). *Informe sobre la situación de la seguridad vial, México 2021 | Secretaría de Salud | Gobierno | gob.mx*. <https://www.gob.mx/salud/documentos/informe-sobre-la-situacion-de-la-seguridad-vial-mexico-2021-331817?state=published>
87. Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the Inception Architecture for Computer Vision. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2818–2826. <https://doi.org/10.1109/CVPR.2016.308>

88. Tabary, M., Ahmadi, S., Amirzade-Iranaq, M. H., Shojaei, M., Sohrabi Asl, M., Ghodsi, Z., Azarhomayoun, A., Ansari-Moghaddam, A., Atlasi, R., Araghi, F., Shafieian, M., Heydari, S. T., Sharif-Alhoseini, M., O'Reilly, G., & Rahimi-Movaghar, V. (2021). The effectiveness of different types of motorcycle helmets – A scoping review. *Accident Analysis and Prevention*, *154*. <https://doi.org/10.1016/j.aap.2021.106065>
89. *tensorflow.org*. (2022). Reentrenamiento de Un Clasificador de Imágenes | TensorFlow Hub. https://www.tensorflow.org/hub/tutorials/tf2_image_retraining
90. Teoh, E. R. (2011). Effectiveness of Antilock Braking Systems in Reducing Motorcycle Fatal Crash Rates. *Traffic Injury Prevention*, *12*(2), 169–173. <https://doi.org/10.1080/15389588.2010.541308>
91. Tonhauser, M., & Ristvej, J. (2021). Implementation of New Technologies to Improve Safety of Road Transport. *Transportation Research Procedia*, *55*, 1599–1604. <https://doi.org/10.1016/J.TRPRO.2021.07.149>
92. Toriumi, A., Abu-Lebdeh, G., Alhajyaseen, W., Christie, N., Gehlert, T., Mehran, B., Mussone, L., Shawky, M., Tang, K., & Nakamura, H. (2022). A multi-country survey for collecting and analyzing facts related to road traffic safety: Legislation, enforcement, and education for safer drivers. *IATSS Research*, *46*(1), 14–25. <https://doi.org/10.1016/J.IATSSR.2022.01.004>
93. United Nations. (2018). *Road Safety Performance Review*.
94. Vashisth, R., Gupta, S., Jain, A., Gupta, S., Sahil, & Rana, P. (2017). Implementation and analysis of smart helmet. *4th IEEE International Conference on Signal Processing, Computing and Control, ISPCC 2017, 2017-January*, 111–117. <https://doi.org/10.1109/ISPCC.2017.8269660>
95. Venkatraman, V., Richard, C. M., Magee, K., Memorial Institute, B., & Johnson, K. (2020). *Countermeasures That Work: A Highway Safety Countermeasure Guide For State Highway Safety Offices*. www.ntis.gov.
96. Wang, B.-S., Chen, P.-Y., Hsieh, Y.-K., Hsieh, J.-W., Chang, M.-C., He, J., Teng, S.-Y., Yue, H., & Tseng, Y.-C. (2023). *PRB-FPN+: Video Analytics for Enforcing Motorcycle Helmet Laws*.
97. Wang, P. (2019). On Defining Artificial Intelligence. *Journal of Artificial*

General Intelligence, 10(2), 1–37. <https://doi.org/10.2478/jagi-2019-0002>

98. Waris, T., Asif, M., Ahmad, M. Bin, Mahmood, T., Zafar, S., Shah, M., & Ayaz, A. (2022). CNN-Based Automatic Helmet Violation Detection of Motorcyclists for an Intelligent Transportation System. *Mathematical Problems in Engineering*, 2022. <https://doi.org/10.1155/2022/8246776>

99. Wei Jia, S. X., Zhen Liang, Yang Zhao, Hai Min, Shujie Li, & Ye Yu. (2021). *Real-time automatic helmet detection of motorcyclists in urban traffic using improved YOLOv5 detector*. <https://doi.org/10.1049/ipr2.12295>

100. Wu, J. (2017). *Introduction to Convolutional Neural Networks*.

101. Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology. *Insights into Imaging*, 9(4), 611–629. <https://doi.org/10.1007/S13244-018-0639-9/FIGURES/15>

102. Yannis, G., Nikolaou, D., Laiou, A., Stürmer, Y. A., Buttler, I., & Jankowska-Karpa, D. (2020). Vulnerable road users: Cross-cultural perspectives on performance and attitudes. *IATSS Research*, 44(3), 220–229. <https://doi.org/10.1016/J.IATSSR.2020.08.006>

103. Yousif, M. T., Sadullah, A. F. M., & Kassim, K. A. A. (2020). A review of behavioural issues contribution to motorcycle safety. *IATSS Research*, 44(2), 142–154. <https://doi.org/10.1016/J.IATSSR.2019.12.001>

104. Yuxin Wu, Alexander Kirillov, Francisco Massa, Wan-Yen Lo, & Ross Girshick. (2019). *GitHub - facebookresearch/detectron2: Detectron2 is a platform for object detection, segmentation and other visual recognition tasks*. <https://github.com/facebookresearch/detectron2>

105. Zafar, A., Aamir, M., Mohd Nawi, N., Arshad, A., Riaz, S., Alruban, A., Dutta, A. K., & Almotairi, S. (2022). A Comparison of Pooling Methods for Convolutional Neural Networks. *Applied Sciences* 2022, Vol. 12, Page 8643, 12(17), 8643. <https://doi.org/10.3390/APP12178643>

106. Zeiler, M. D., & Fergus, R. (2014). Visualizing and Understanding Convolutional Networks arXiv:1311.2901v3 [cs.CV] 28 Nov 2013. *Computer Vision–ECCV 2014*, 8689(PART 1), 818–833. https://doi.org/10.1007/978-3-319-10590-1_53

107. Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., Member, S., Xiong, H.,

& He, Q. (2020). *A Comprehensive Survey on Transfer Learning*.

Anexos

Se publicó en fecha 10 de mayo del presente año el artículo titulado “Detection of Helmet Use in Motorcycle Drivers Using Convolutional Neural Network en la revista indexada “Applied Sciences” de la editorial “MDPI”.



Article

Detection of Helmet Use in Motorcycle Drivers Using Convolutional Neural Network

Jaime Mercado Reyna ¹, Huizilopoztli Luna-García ^{1,*}, Carlos H. Espino-Salinas ¹, José M. Celaya-Padilla ¹, Hamurabi Gamboa-Rosales ¹, Jorge I. Galván-Tejada ¹, Carlos E. Galván-Tejada ¹, Roberto Solís Robles ¹, David Rondon ² and Klinge Orlando Villalba-Condon ³

- ¹ Unidad Académica de Ingeniería Eléctrica, Universidad Autónoma de Zacatecas, Jardín Juárez 147, Centro, Zacatecas 98000, Mexico; jaime.mercadoreyna@uaz.edu.mx (J.M.R.); carlospino@uaz.edu.mx (C.H.E.-S.); hamurabigr@uaz.edu.mx (H.G.-R.); gtejo@uaz.edu.mx (J.I.G.-T.); ericgalvan@uaz.edu.mx (C.E.G.-T.); rsolis@uaz.edu.mx (R.S.R.)
- ² Departamento Estudios Generales, Universidad Continental, Arequipa 04001, Peru; drondon@continental.edu.pe
- ³ Vicerrectorado de Investigación, Universidad Católica de Santa María, Arequipa 04002, Peru; kvillalba@ucsm.edu.pe
- * Correspondence: hluna@uaz.edu.mx (H.L.-G.); jose.celaya@uaz.edu.mx (J.M.C.-P.)

Abstract: The lack of helmet use in motorcyclists is one of the main risk factors with severe consequences in traffic accidents. Wearing a certified motorcycle helmet can reduce the risk of head injuries by 69% and fatalities by 42%. At present there are systems that detect the use of the helmet in a very precise way, however they are not robust enough to guarantee a safe journey, that is why is proposed an intelligent model for detecting the helmet in real time using training images of a camera mounted on the motorcycle, and convolutional neural networks that allow constant monitoring of the region of interest to identify the use of the helmet. As a result, a model was obtained capable of identifying when the helmet is used or not in an objective and constant manner while the user is making a journey, with a performance of 97.24%. Thus, it was possible to conclude that this new safety perspective provides a first approach to the generation of new preventive systems that help reduce accident rates in these means of transport. As future work, it is proposed to improve the model with different images that may violate the helmet detection.

Keywords: helmet detection; deep learning; InceptionV3; convolutional neural network; motorcyclist safety



Citation: Mercado Reyna, J.; Luna-García, H.; Espino-Salinas, C.H.; Celaya-Padilla, J.M.; Gamboa-Rosales, H.; Galván-Tejada, J.I.; Galván-Tejada, C.E.; Solís Robles, R.; Rondon, D.; Villalba-Condon, K.O. Detection of Helmet Use in Motorcycle Drivers Using Convolutional Neural Network. *Appl. Sci.* **2023**, *13*, 5882. <https://doi.org/10.3390/app13105882>

Academic Editor: Krzysztof Koszala

Received: 18 April 2023

Revised: 3 May 2023

Accepted: 9 May 2023

Published: 10 May 2023



Copyright: © 2023 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

The means of transport have been changing over the last few years, and the use of motorbikes has been increasing, as a result of the growth of the middle class who are looking for affordable vehicles, and also because of the urbanization from which a new demand for mobility is derived, which is mainly has seen coverage by the individual private transport industry [1]. The financing facilities to acquire these vehicles, better fuel economy, their ability to manage on different terrains and in conditions where traffic is congested, and low maintenance costs are major factors driving their use in lower-middle income countries [2,3]. This development inevitably also exposes the users of this means of transport to negative consequences such as traffic accidents, in which the potential damage is usually high for motorcyclists and their passengers, since there is no structure of the motorcycle that protects them as if it happens in four-wheeled vehicles [4].

Road traffic crashes cause more than 1.35 million deaths annually and are the first cause of death in children and young adults; in particular, 28% of these deaths globally correspond to users of two- or three-wheeled vehicles. Among the leading causes of death, serious injury and disability of motorcyclists are head and neck injuries, which

En el mes de noviembre del año 2022, se presentaron los avances de la investigación en el Segundo Coloquio en Procesamiento y análisis de datos dentro del cual se obtuvo el reconocimiento como “Mejor Ponencia” del evento, el cual es organizado por la coordinación de la Maestría en Ciencias del Procesamiento de la Información.

