UNIVERSIDAD NACIONAL DE MOQUEGUA

ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS E INFORMÁTICA

Seguimiento del iris con machine learning para la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, Moquegua, 2024

TESIS

PRESENTADO POR:

BACH. OSCAR ALI HUACO LIMACHE

ASESOR:

MGR. JOSÉ ANTONIO GUZMÁN VALDIVIA

PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO DE SISTEMAS E INFORMÁTICA

MOQUEGUA - PERÚ

2025

UNAM
UNIVERSIDAD NACIONAL DE MOQUEGUA

ESCUELA PROFESIONAL DE
INGENIERÍA DE SISTEMAS E INFORMÁTICA

Folio Nº 018

ACTA DE SUSTENTACIÓN

I. Modalidad:

Tesis	:	X
Trabajo de Suficiencia Profesional	:	
Otro:	:	

II. Documento de aprobación para la sustentación:
Resolución de Facultad N° 0069-2025-D-FACIA-UNAM

Fecha: 27 de Marzo 2025

III. El jurado ha dictaminado la (el) Tesis, TITULADO:
"Seguimiento del Iris con Machine Learning para la detección de distracciones en el Sistema de Monitoreo de somnolencia en conductores interprovinciales, Moquegua 2024"

Bachiller: Oscar Alí Huaco Limache

Asesor Principal: José Antonio Guzmán Valdivia

Co-Asesor: —

IV. Se dictamina:
Como: Aprobado por Unanimidad la sustentación de manera:

Presencial [X] Virtual [ ]

Con nota: Dieciseis (16) por lo que; Sí [X] No [ ]

Opta el Título Profesional de INGENIERO DE SISTEMAS E INFORMÁTICA.

Siendo las 13:14 horas, del 01 de Abril del año 2025 se procede con la firma en conformidad de lo dictaminado por el Jurado.

Dr. Carlos Alberto Silva Cárdenas
Presidente

Ender Tito Chura
Primer Miembro

Marcos Gonzalo Rosa A.
Segundo Miembro

Bachiller

01

DEDICATORIA

Dedico este trabajo de investigación a mis padres y mi hermano por motivarme a continuar en mi formación profesional y apoyarme en todo momento donde los necesite estando presentes como una familia unida y con un hogar amoroso.

A toda mi familia y todos aquellos que, de una u otra manera, han estado presentes brindándome su cariño, sus palabras de aliento y su fe en mis capacidades. Su apoyo ha sido fundamental para llegar hasta aquí.

A mis amigos, quienes, sin importar las circunstancias, han estado ahí con su compañía, consejos y aliento. Su presencia ha sido un recordatorio constante de que no camino solo y de que, incluso en los momentos difíciles, la amistad verdadera siempre se hace notar.

A mis mentores y profesores, quienes con su conocimiento, orientación y exigencia me han impulsado a superarme. Gracias por compartir su sabiduría y por ser una fuente de inspiración en mi formación académica y profesional.

Resumen

En 2021 se registraron aproximadamente 1,19 millones de muertes ocasionadas por accidentes de tránsito, lo que representa un descenso del 5 % en comparación con 2010. Frente a esta problemática, la presente investigación tuvo como objetivo desarrollar un sistema capaz de detectar distracciones en conductores interprovinciales mediante el seguimiento del iris con técnicas de machine learning, integrándolo en un sistema existente de monitoreo de somnolencia.

La metodología se estructuró en cinco fases ejecutadas secuencialmente, con un enfoque iterativo para optimizar continuamente la precisión del modelo antes de su implementación en un entorno real. Se emplearon modelos avanzados de visión por computadora, como MediaPipe Face Mesh y Bazeface, para el análisis de videos recopilados, extrayendo datos relevantes en formato CSV para su posterior procesamiento. El sistema identificó y monitoreó puntos de referencia oculares, incluyendo la pupila y puntos extremos del ojo, midiendo distancias clave para determinar la dirección de la mirada.

Los resultados demostraron que el modelo propuesto logró detectar con alta precisión la desviación lateral de la mirada, lo que permitió diferenciar entre una conducción atenta y una situación de distracción. Se concluye que la metodología aplicada es efectiva para mejorar la seguridad vial y puede integrarse a sistemas de asistencia al conductor, contribuyendo a la reducción de accidentes por distracción.

Palabras clave: seguimiento del iris, machine learning, visión por computadora, detección de distracciones, seguridad vial, conductores interprovinciales.

Abstract

In 2021 an estimated 1.19 million deaths were caused by road traffic accidents, representing a 5% decrease compared to 1.25 million deaths in 2010. In response to this issue, this research aimed to develop a system capable of detecting driver distractions in interprovincial transport by using iris tracking with *machine learning* techniques, integrated into an existing drowsiness monitoring system.

The methodology was structured into five sequential phases, implemented with an iterative approach to continuously improve the model's accuracy before deployment in real-world conditions. Advanced computer vision models, such as MediaPipe Face Mesh and Bazeface, were employed to analyze collected video data, extracting relevant information in CSV format for further processing. The system identified and tracked ocular landmarks, including the pupil and extreme eye points, measuring key distances to determine gaze direction.

The results showed that the proposed model achieved high accuracy in detecting lateral gaze deviation, enabling the differentiation between attentive driving and distracted situations. It is concluded that the applied methodology is effective for enhancing road safety and can be integrated into driver assistance systems, contributing to the reduction of distraction-related accidents.

Keywords: iris tracking, *machine learning*, computer vision, distraction detection, road safety, interprovincial drivers.

Índice general

I. Planteamiento del problema 9
1.1. Descripción y formulación del problema 11
1.1.1. Problema general 13
1.1.2. Problemas específicos 14
1.2. Objetivos 14
1.2.1. Objetivo general 14
1.2.2. Objetivos específicos 14
1.3. Justificación 15
1.4. Variables 16
II. Marco teórico 17
2.1. Antecedentes 17
2.2. Bases teóricas 20
2.2.1. Inteligencia Artificial 20
2.2.2. Aprendizaje automático 20
2.2.3. Aprendizaje profundo 21
2.2.4. Redes Neuronales Profundas 21
2.2.5. Face Detection Models 21
2.2.6. BlazeFace 22
2.2.7. Face Landmark Model 22
2.3. Definición de términos 23
III. Metodología 24
3.1. Tipo y nivel de investigación 24
3.2. Ámbito temporal y espacial 24
3.3. Diseño de investigación 24
3.4. Población y muestra 25
3.4.1. Población. 25

3.4.2. Muestra 25
3.5. Instrumentos 26
3.5.1. Técnicas de recolección de información 26
3.5.2. Herramientas de software 26
3.6. Procedimientos 27
3.6.1. Fase 1 obtención de la información 27
3.6.2. Fase 2 Preprocesamiento de los datos 29
3.6.3. Fase 3 Modelo de detección 32
3.6.4. Fase 4 Evaluación de resultados 40
3.6.5. Fase 5 Implementación 50
3.7. Análisis de datos 54
IV. Resultados y discusión 56
4.1. Resultados 56
4.2. Discusión 58
V. Conclusiones 60
VI. Recomendaciones 61
VII. Referencias 62
VIII. Anexo 68
ANEXO 1: Matriz de consistencia 68

Índice de Ilustraciones

Ilustración 1 Siniestros en red vial nacional, periodo 2022..... 12

Ilustración 2 Fallecidos en red vial nacional, periodo 2022..... 12

Ilustración 3 Heridos en red vial nacional, periodo 2022..... 13

Ilustración 4 Variación de la condición de estrabismo..... 29

Ilustración 5 Conductor con accesorios en el rostro..... 30

Ilustración 6 Conductor con condiciones especiales..... 31

Ilustración 7 Irregularidades en videos..... 32

Ilustración 8 Single BlazeBlock y Double BlazeBlock..... 33

Ilustración 9 Detección de rostros..... 35

Ilustración 10 Expresión referencial de Loss Function..... 37

Ilustración 11 División de las zonas de detección..... 39

Ilustración 12 Resultados de evaluación de frames..... 40

Ilustración 13 Variabilidad de la detección..... 44

Ilustración 14 Distribución del índice de Estabilidad..... 45

Ilustración 15 Resultados del tiempo de distracción..... 45

Ilustración 16 Irregularidades en la desviación estándar..... 46

Ilustración 17 Persona 1 con estrabismo..... 47

Ilustración 18 Irregularidades en la detección de la persona 2..... 48

Ilustración 19 Ruido en la detección de la persona 9..... 48

Ilustración 20 Uso de lentes oftálmicos de persona 4..... 49

Ilustración 21 Implementación de MediaPipe "face_landmarker.task 50

Ilustración 22 Class distractionDetector 51

Ilustración 23 Función distance_calculate 51

Ilustración 24 Detección de la distracción izquierda y derecha 52

Ilustración 25 Detección de somnolencia micro sueño y bostezo 52

Ilustración 26 Conteo de distracciones y monitoreo de somnolencia 53

Ilustración 27 Archivos de almacenamiento de alarma 53

Ilustración 28 Alarmas mostradas 54

Ilustración 29 Tiempo total por distracciones 54

Ilustración 30 % Distracción y % Detección 56

Ilustración 31 Resultados de las detecciones 57

Ilustración 32 Dataset de imagenes de conductores 58

Índice de Tablas

Tabla 1 Características de videos 30

Tabla 2 Arquitectura de red de extracción de características 34

Tabla 3 Puntos referenciales extraídos 35

Tabla 4 Evaluación por genero 38

Tabla 5 Evaluación por tono de piel 38

Tabla 6 Resultados de zona de detección 39

Tabla 7 Conjunto de datos analizados 44

Tabla 8 Análisis de los resultados de la persona 1 46

Tabla 9 Resultados del tiempo de distracción de la persona 4 49

Tabla 10 Resultados de investigación 57

Introducción

En un escenario global donde la seguridad vial sigue siendo un desafío prioritario, los accidentes de tránsito continúan cobrando vidas y generando graves consecuencias económicas y sociales. Según el Global Status Report on Road Safety 2023 de la Organización Mundial de la Salud (OMS), en 2021 se registraron aproximadamente 1,19 millones de muertes por accidentes de tránsito, cifra que, si bien representa una reducción del 5 % respecto a 2010, sigue evidenciando la urgencia de implementar soluciones más efectivas. En el contexto peruano, la situación se agrava por factores como la informalidad en el transporte interprovincial, las largas jornadas de manejo y la exposición a condiciones de conducción monótonas, las cuales incrementan el riesgo de somnolencia y distracciones al volante.

En respuesta a esta problemática, el presente proyecto de tesis propone el desarrollo de un sistema de seguimiento del iris basado en técnicas de machine learning y visión por computadora, diseñado para detectar distracciones en conductores interprovinciales e integrarse a un sistema ya existente de monitoreo de somnolencia. Este sistema utiliza modelos avanzados como MediaPipe Face Mesh y BlazeFace para identificar y rastrear puntos de referencia en los ojos, medir distancias clave y determinar la dirección de la mirada, permitiendo así diferenciar entre una conducción atenta y una situación de distracción lateral.

La investigación se sustenta en un enfoque metodológico estructurado en cinco fases secuenciales con carácter iterativo, lo que asegura la mejora continua de la precisión del modelo antes de su implementación real. El análisis se llevó a cabo utilizando un conjunto de datos compuesto por más de 31 horas de grabaciones de conductores en condiciones reales de trabajo, lo que permite validar la robustez y aplicabilidad del sistema en entornos reales. Los resultados alcanzaron un promedio del 93 % de precisión en la detección de distracciones, demostrando que la propuesta es técnicamente viable y puede contribuir significativamente a la prevención de accidentes de tránsito.

La estructura de la tesis se organiza de la siguiente manera:

En el Capítulo I se presenta el planteamiento del problema, los objetivos, la justificación y las variables de estudio, estableciendo el marco inicial de la investigación.

En el Capítulo II se expone el marco teórico, que incluye antecedentes nacionales e internacionales, así como las bases conceptuales y tecnológicas que sustentan el uso de inteligencia artificial y visión por computadora en la detección de distracciones y somnolencia.

El Capítulo III describe la metodología empleada, detallando el tipo y nivel de investigación, el diseño, la población y muestra, los instrumentos y procedimientos aplicados.

En el Capítulo IV se presentan los resultados obtenidos y su discusión, analizando el desempeño del sistema y comparando los hallazgos con estudios previos.

Finalmente, el Capítulo V expone las conclusiones y el Capítulo VI presenta las recomendaciones para futuras investigaciones y mejoras del sistema.

Este proyecto de tesis no solo busca aportar una solución tecnológica innovadora al campo de la seguridad vial, sino también sentar las bases para que este tipo de sistemas pueda replicarse en otras áreas de transporte y sectores donde la atención del operador sea un factor crítico. La implementación de un sistema de seguimiento del iris con machine learning representa un paso importante hacia la reducción de accidentes por distracción en el transporte interprovincial, mejorando así la seguridad de los conductores y pasajeros en el Perú.

I. Planteamiento del problema

1.1. Descripción y formulación del problema

Según el informe *Global Status Report On Road Safety 2023* de la Organización Mundial de la Salud (OMS), en el año 2021 se estimó unos 1,19 millones de muertes ocasionadas por accidentes de tránsito, un descenso del 5% en comparación con 1,25 millones de muertes ocasionadas en 2010.

Aun así, el desafío mundial para la salud y el desarrollo a nivel mundial son las muertes y lesiones causadas por accidentes de tránsito. En 2019 la causa principal de muertes entre niños y jóvenes de 5 años a 29 años fue de accidentes de tránsito, es la duodécima causa de muerte cuando se consideran por edades (World health organization, 2023).

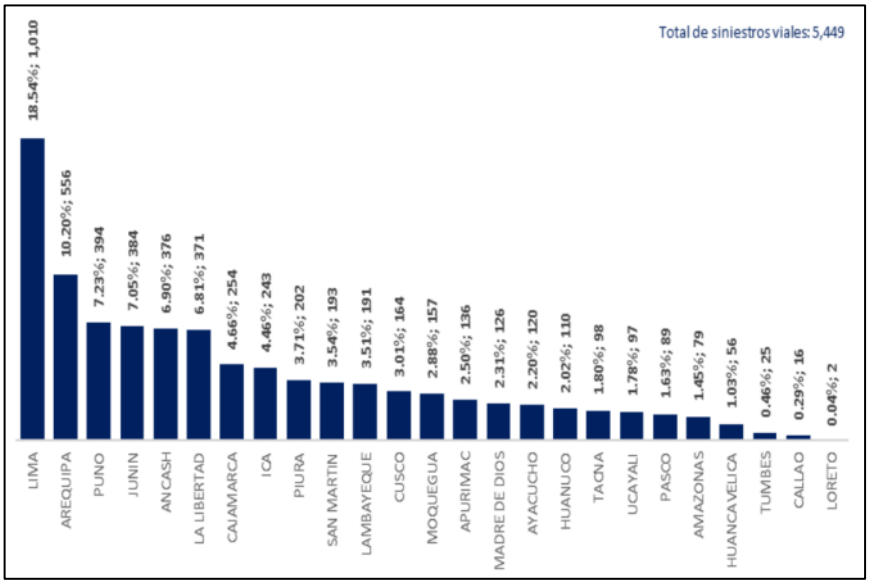
A pesar de la complejidad inherente al sistema de transporte peruano, la informalidad en el transporte interprovincial emerge como un desafío constante y preocupante, generando como consecuencia un aumento significativo en el número de accidentes (Rupay, 2018).

La tasa promedio de la población afectada por siniestros de tránsito ha sido de 3,8% entre los años 1991 y 2019, esto está por encima del crecimiento poblacional deportado por el INEI en este periodo de tiempo (Ministerio de transportes y comunicaciones, 2023).

El creciente flujo vehicular y de pasajeros en los últimos años ha desencadenado un aumento significativo en la tasa de accidentes de tránsito. Los datos del 2017 en la carretera central Lima a Huancayo, eje transversal importante de vía de comunicación en el Perú, revelan cifras alarmantes: 1227 accidentes, 49 fallecidos, 409 heridos graves y pérdidas económicas que superan los 249 millones (Ministerio de transportes y comunicaciones, 2017). Aunque el plan estratégico vigente reconoce al factor humano como la principal causa, omite elementos cruciales como la calidad del sueño, la somnolencia y la exposición a grandes altitudes, los cuales podrían estar influyendo significativamente en la ocurrencia de estos siniestros (Huamán Olarte & Mujica Alban, 2020).

Ilustración 1

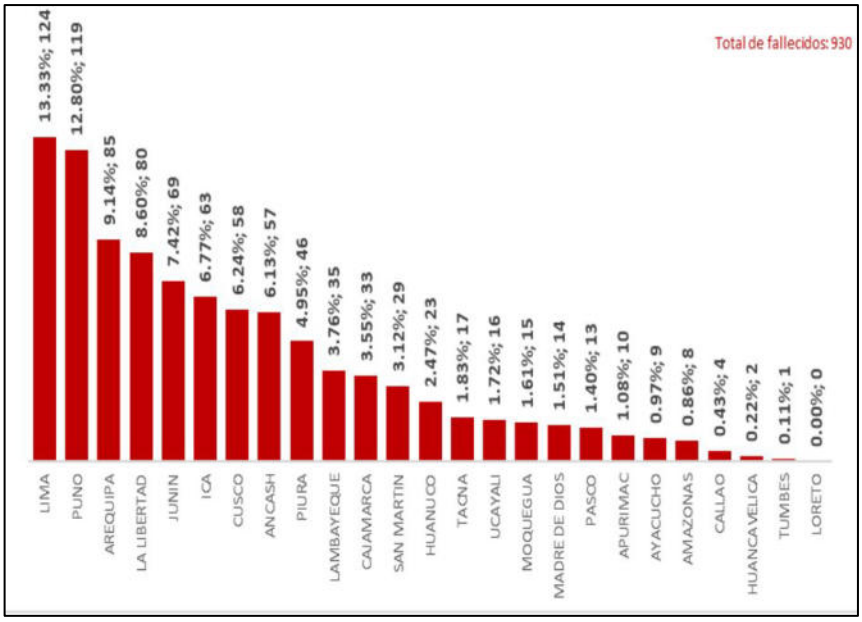
Siniestros en red vial nacional, periodo 2022



Fuente: Reporte estadístico de siniestros viales 2022 Super intendencia de transporte terrestre de personas (2022)

Ilustración 2

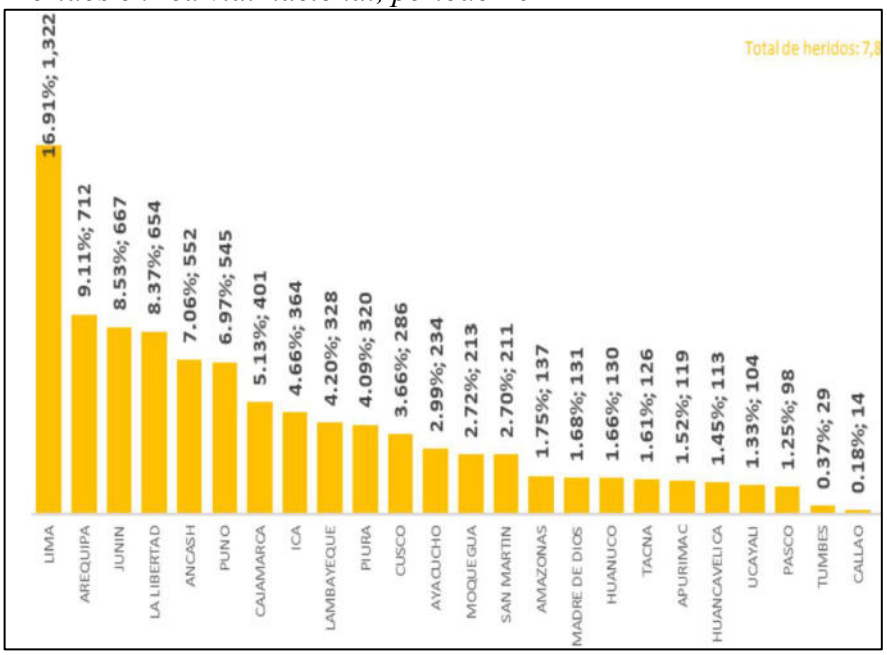
Fallecidos en red vial nacional, periodo 2022



Fuente: Reporte estadístico de siniestros viales 2022 Super intendencia de transporte terrestre de personas (2022)

Ilustración 3

Heridos en red vial nacional, periodo 2022



Fuente: Reporte estadístico de siniestros viales 2022 Super intendencia de transporte terrestre de personas (2022)

Existen sistemas de detección de somnolencia que emplean sensores oculares para monitorear la frecuencia de parpadeo del conductor. Al superar un umbral predefinido, se activa una alarma. Por otro lado, la inteligencia artificial, mediante técnicas de procesamiento de imágenes y redes neuronales, permite detectar los ojos del conductor utilizando algoritmos generando alertas ante signos de somnolencia (Cano Lara et al., 2022).

1.1.1. Problema general

¿Cómo se halla, mediante el seguimiento del iris con machine learning, la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, en Moquegua 2024?

1.1.2. Problemas específicos

- ¿Qué nivel asegura la precisión del modelo de machine learning para la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, en Moquegua 2024?
- ¿Qué capacidad de integración tiene el sistema para la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, en Moquegua 2024?
- ¿Cómo optimizar el tiempo de procesamiento del sistema para la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, en Moquegua 2024?

1.2. Objetivos

1.2.1. Objetivo general

Hallar mediante el seguimiento del iris con machine learning la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, en Moquegua 2024

1.2.2. Objetivos específicos

- Hallar el nivel que asegure la precisión del modelo de machine learning para la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, en Moquegua 2024
- Hallar la capacidad de integración que tiene el sistema para la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, en Moquegua 2024
- Optimizar el tiempo de procesamiento del sistema para la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, en Moquegua 2024

1.3. Justificación

Justificación Teórica: Esta investigación se basa en el uso de las diversas tecnologías de inteligencia artificial como el seguimiento ocular mediante visión por computadora para detectar distracciones en conductores. Estudios científicos demostraron que el análisis de los movimientos oculares permite detectar los niveles de atención y posibles estados de distracción y somnolencia los cuales están vinculados con los siniestros de tránsito. Sin embargo, en nuestro contexto nacional es limitada la implementación de estos avances en el ámbito de la seguridad vial, por lo que se busca apoyar el desarrollo de estas soluciones tecnológicas basada en fundamentos teóricos de aprendizaje automático y visión computacional, contribuyendo así a cerrar la brecha existente entre la ciencia actual y su aplicación en el transporte terrestre en el Perú.

Justificación Práctica: El desarrollo de un sistema de monitoreo que identifique en tiempo real las distracciones y somnolencias en conductores interprovinciales es crucial puesto que esto contribuirá en reducir la ocurrencia de siniestros viales derivados del factor humano, el cual se considera por el *Plan Estratégico Nacional de Seguridad Vial 2017–2021* cual. Este sistema puede ser integrado como herramienta preventiva, facilitando así la toma de decisiones para así poder mejorar la seguridad de los pasajeros y disminuir las perdidas tanto humanas como materiales. También podrá escalar en otra categoría de transporte como en las políticas de seguridad en el ámbito de la minería como una medida de prevención de accidentes.

Justificación Social: Si bien es cierto que el grupo de estudios son los choferes interprovinciales la relevancia del estudio brindará mayor seguridad a los pasajeros en los viajes interprovinciales y se reducirá la tasa de accidentes de tránsito aumentando la confiabilidad en este tipo de viajes que son comúnmente realizados.

Justificación Metodológica: Investigaciones previas demuestran que es factible analizar la somnolencia con un nivel de precisión aceptable, sin embargo, con el avance de la tecnología se presentan mejores métodos para resolver estos

problemas con mejores resultados, el uso de la inteligencia artificial es de los métodos más actuales y por ende debe ser adaptado en nuestra perspectiva social.

1.4. Variables

Variable Independiente: Seguimiento del iris con Machine Learning.

Variable Dependiente: Detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales.

II. Marco teórico

2.1. Antecedentes

2.1.1. Internacionales

Benites Cespedes (2024) en su investigación, *Desarrollo de un sistema de alerta de fatiga para conductores viales*, se centró en detectar la fatiga en conductores, empleando sensores no intrusivos que se colocan en el vehículo. Para el diseño y prueba del sistema, se usaron simuladores como Tinkercad y Arduino, logrando construir un prototipo funcional que puede instalarse en el volante de cualquier automóvil. Las pruebas realizadas demostraron una detección eficaz de la somnolencia, ofreciendo una solución económica y accesible para mejorar la seguridad vial.

Delgado Egas & Yandún Velasteguí (2022) implementó, en su estudio *Sistema de detección de somnolencia para conductores de taxis en la ciudad de Tulcán*, un sistema que detecta la somnolencia mediante el uso de un sensor de obstáculo infrarrojo, capaz de detectar cuando los ojos del conductor permanecen cerrados por un tiempo prolongado. Al detectar este comportamiento, un dispositivo ***Buzzer*** emite una alarma para alertar al conductor. Además, se desarrolló una aplicación móvil, que, a través de un módulo de comunicación Bluetooth, gestiona el sistema, almacena los resultados y facilita la administración de usuarios. Este enfoque integra tecnología accesible para una alerta eficiente en tiempo real.

Granda Zaruma & Valdivieso Delgado (2021) desarrollaron un *Sistema de detección de somnolencia a través de visión asistida por computadora en el periodo abril* centrándose en el diseño de dispositivos electrónicos basados en visión asistida por computadora para prevenir accidentes de tránsito. El sistema utiliza el análisis del Aspecto de Relación Ocular (EAR), que mide la frecuencia de parpadeo y el tiempo que los ojos permanecen cerrados. Las técnicas de investigación documental, observación y prueba y error sirvieron para recopilar y seleccionar información y material necesario basado en el comportamiento de la persona ante

estas condiciones que presenta el conductor al estar al volante. Con base en los resultados, con una efectividad del 92%, el dispositivo segmenta la ubicación de los ojos, clasifica ojo derecho e izquierdo, lleva a cabo un monitoreo constante y de tiempo real analizando la orientación del rostro del conductor.

Safarov et al. (2023) desarrollaron un *sistema de detección de somnolencia en tiempo real utilizando análisis de parpadeo de ojos y visión por computadora.* Este estudio muestra cómo el parpadeo de los ojos puede correlacionarse con la somnolencia y cómo las redes neuronales profundas mejoran la detección precisa en condiciones de conducción real. Utilizaron datos personalizados para el entrenamiento del modelo y se obtuvieron resultados experimentales para diferentes candidatos. El rendimiento general del modelo de detección de somnolencia fue de 95,8% de precisión para la detección de ojos somnolientos, 97% para la detección de ojos abiertos, 0,84% para la detección de bostezos, 0,98% para caídas del lado derecho y 100% para caídas del lado izquierdo.

Jebraeily et al. (2024),en su investigación titulada *Driver Drowsiness Detection Based on Convolutional Neural Network Architecture Optimization Using Genetic Algorithm*, se utilizaron mecanismo de búsqueda de arquitectura de red para obtener una estructura óptima para una red neuronal convolucional que pueda detectar eficazmente la somnolencia del conductor. Esta investigación propone enriquecer el conjunto de datos y abordar las deficiencias en los conjuntos de datos existentes, y una estructura óptima de red neuronal convolucional incluyendo el número de capas y el tipo de función objetivo. El método propuesto superó a otros enfoques en exactitud y precisión, logrando una tasa de precisión de aproximadamente el 99,8%.

Yang y Yi (2024) presentan la investigación *Enhancing Road Safety: Deep Learning-Based Intelligent Driver Drowsiness Detection for Advanced Driver-Assistance* donde aplicaron una técnica de detección inteligente de la somnolencia del conductor basada en aprendizaje profundo para sistemas avanzados de asistencia al conductor (DLID3- ADAS). La técnica DLID3-ADAS, se derivan características complejas de las imágenes. Además, se utiliza el algoritmo Northern Goshawk Optimization (NGO) para la selección de hiperparámetros óptimos para

el modelo ShuffleNett. Por último, se utiliza un modelo de máquina de aprendizaje extremo (ELM) para detectar y clasificar adecuadamente los estados de somnolencia de los conductores. Este sistema además de detectar el estado de somnolencia del conductor también optimiza el procesamiento de los datos, permitiendo una detección rápida y eficiente en entornos de alta demanda, logrando un mayor rendimiento en comparación con los modelos existentes, con una precisión máxima del 97,05% y un tiempo computacional mínimo de 0,60 s.

2.1.2. Nacionales

Jain et al. (2021) Esta investigación, *Real-Time Driver Drowsiness Detection using Computer Vision*, utiliza el sistema EAR (Eye Aspect Ratio) para calcular la relación de las distancias entre los puntos de referencia horizontales y verticales del ojo, necesaria para detectar la somnolencia. Para detectar el bostezo, se calcula un valor YAWN utilizando la distancia entre el labio inferior y el labio superior, y la distancia se compara con un valor umbral. Sé usa un módulo eSpeak (sintetizador de texto a voz) que se utiliza para dar alertas de voz adecuadas cuando el conductor se siente somnoliento o está bostezando. La precisión medida en la fase de análisis de rendimiento es casi del 100% en el caso de que la cara esté correctamente alineada y no haya ningún obstáculo portátil. La precisión disminuye un poco cuando hay un obstáculo (por ejemplo, un sombrero). Las condiciones de iluminación ambiental son muy importantes para obtener resultados adecuados.

En esta investigación de Armando & Flores (2024) , titulada *Desarrollo e implementación en un sistema embebido de un sistema detector de la distracción en conductores mediante la estimación de la postura de la cabeza,* se desarrolló e implemento un detector de distracciones en la ciudad de Cusco basándose en la estimación de la postura de la cabeza usando la tecnología de las redes neuronales convolucionales en un Orange Pi 5 capaz de ejecutar estos modelos y estimar los ángulos de rotación de la cabeza. Se compraron 12 modelos MNASNet1-0 seleccionados por su desempeño destacado. Al realizar las pruebas del prototipo en un entorno real controlado alcanza una exactitud promedio del 93,58%, una precisión del 90,05%, una sensibilidad promedio de 96.5% y una puntuación F1 promedio de 93,09%.

Mayon & Limaquispe (2018) desarrollaron un *Sistema de detección de somnolencia mediante inteligencia artificial en conductores de vehículos para alertar la ocurrencia de accidentes de tránsito* desarrollando un prototipo de un sistema de control del estado de somnolencia en conductores de vehículos utilizando C# con EmguCV para detectar de ojos abiertos, cerrados distracción y orientación y un sistema de alarma con un zumbador de 12 V, que recibe la orden del microcontrolador Raspberry PI 3 que a su vez la recibe desde el software de implementación de visión artificial y de una red neuronal.

2.2. Bases teóricas

2.2.1. Inteligencia Artificial

Es la habilidad que poseen las máquinas para imitar el razonamiento humano a través de algoritmos complejos. Estas máquinas pueden procesar grandes cantidades de datos, aprender de ellos y utilizar ese conocimiento para tomar decisiones de manera autónoma. Esta capacidad se manifiesta en diversas aplicaciones, desde la identificación precisa de objetos en imágenes hasta la optimización de estrategias comerciales. Además, la IA está transformando nuestra vida cotidiana al proporcionarnos recomendaciones personalizadas y predicciones en áreas como la salud, la educación y las relaciones sociales, lo que la convierte en una tecnología con un impacto cada vez mayor en múltiples aspectos de nuestra existencia (Rouhiainen, 2018).

2.2.2. Aprendizaje automático

Según Dias Ramires (2021) define el aprendizaje automático (Machine Learning) como una rama de la inteligencia artificial que capacita a las computadoras para aprender de manera autónoma a partir de datos, sin necesidad de ser programadas explícitamente para cada tarea. Desde el punto de vista de la ingeniería se define como programa de computador que aprende de una experiencia denominada *E*, con respecto a una tarea definida por *T* y una medida de rendimiento llamada *R*, si su rendimiento en la tarea, medido por *R*, mejora con la experiencia.

2.2.3. Aprendizaje profundo

Se puede definir el aprendizaje profundo (deep learning) como una parte del machine learning, se inspira en el funcionamiento humano tanto como la estructura y la función de las redes neuronales basándose en sus algoritmos y técnicas para desarrollar las mismas actividades de un ser humano y que pueda coexistir en los diferentes campos en el que vivimos (Paxi, 2023).

Goodfellow et al. (2016) define al Deep Learning como un subcampo del Machine Learning que utiliza redes neuronales artificiales de varios tipos y con múltiples capas como son las Redes Neuronales Convolucionales (CNN), Redes Neuronales Recurrentes (RNN), Redes Neuronales Evolutivas (ENN), etc. Estas redes llegan a aprender a través de procesos de entrenamiento con grandes conjuntos de datos actualizando los parámetros de la red para reducir la función de perdida.

2.2.4. Redes Neuronales Profundas

Las Redes Neuronales Profundas (DNN), es un modelo computacional que se basa en la estructura y funcionamiento de las redes neuronales artificiales caracterizándose por la presencia de múltiples capas ocultas entre la capa de entrada y salida. Estas logran modelar representaciones jerárquicas de los datos, permitiendo la extracción de características de alto nivel a partir de datos de entrada crudos (Lecun et al., 2015).

2.2.5. Face Detection Models

La detección facial es una técnica de visión por computadora que identifica rostros humanos en imágenes o videos. Su desarrollo ha sido fundamental en diversas aplicaciones como reconocimiento facial, análisis de emociones, seguridad biométrica y realidad aumentada (Viola & Jones, 2001).

Inicialmente, los métodos de detección facial se basaban en técnicas de procesamiento de imágenes y aprendizaje automático tradicional, pero con el

avance del aprendizaje profundo, los modelos actuales han mejorado significativamente en precisión y eficiencia (Viola & Jones, 2001).

2.2.6. BlazeFace

BlazeFace es un modelo de detección de rostros desarrollado por Google, diseñado específicamente para su uso en dispositivos móviles con GPUs integradas. Su principal ventaja radica en su capacidad para operar en tiempo real, alcanzando velocidades de doscientos a más de mil fotogramas por segundo en dispositivos de alta gama. Esta eficiencia lo hace ideal para aplicaciones de realidad aumentada que requieren una detección facial precisa y rápida (Bazarevsky et al., 2019).

El modelo se basa en una red neuronal convolucional ligera, inspirada en arquitecturas como MobileNetV1/V2, pero con modificaciones específicas para optimizar la extracción de características faciales. Además, emplea un esquema de anclaje adaptado del Single Shot MultiBox Detector (SSD), optimizado para un uso eficiente de la GPU. Para mejorar la resolución de conflictos entre predicciones superpuestas, BlazeFace implementa una estrategia alternativa a la supresión no máxima, lo que contribuye a una detección más estable y suave (Bazarevsky et al., 2019).

2.2.7. Face Landmark Model

El modelo genera una malla relativamente densa de 468 vértices, lo que lo hace adecuado para aplicaciones de realidad aumentada que requieren efectos basados en la cara. Una de sus principales ventajas es su capacidad para operar en tiempo real en GPUs móviles, alcanzando velocidades de cien a más de mil fotogramas por segundo, dependiendo del dispositivo y la variante del modelo. Además, la calidad de sus predicciones es comparable a la variabilidad encontrada en anotaciones manuales de las mismas imágenes (Kartynnik et al., 2019).

La arquitectura del modelo está optimizada para dispositivos móviles, lo que permite su implementación en aplicaciones que requieren procesamiento en tiempo real sin sacrificar precisión. Este enfoque ha sido fundamental para el

desarrollo de efectos de realidad aumentada basados en la detección y modelado de la geometría facial (Kartynnik et al., 2019).

2.3. Definición de términos

- Inteligencia Artificial (IA): Ponce Gallegos et al. (2014) expresa como "una de las ramas de las ciencias de la computación que más interés ha despertado en la actualidad, debido a su enorme campo de aplicación" (p. 16).
- Aprendizaje Automático (Machine Learning): Según Géron (2019) es "la ciencia (y el arte) de programar computadoras para que puedan aprender de los datos" (p. 2).
- Visión artificial: Danilo & Santillán (2008) comenta que "La visión artificial es una disciplina compleja que involucra otras ciencias, intenta emular la capacidad que tienen algunos seres vivos para ver una escena y entenderla; conjuntamente con el PDI, han experimentado una rápida evolución en las dos últimas décadas." (p. 3).
- Detección de Rostros: Según Morales Gonzales et al. (2024), "La detección de rostros es una técnica esencial en la inteligencia artificial, utilizada en una amplia gama de aplicaciones que van desde la seguridad hasta la interacción humano-computadora." (p. 316).
- MediaPipe: Según Sanchis Reig & Pujol Lopez (2022) es "un framework para desarrollar pipelines de ML que permitan procesar series temporales de datos como vídeos o audios" (p. 7).

III. Metodología

3.1. Tipo y nivel de investigación

La investigación es de tipo aplicativa, Lozada (2014) expone que este tipo de investigación tiene como objetivo crear conocimiento con la aplicación directa en la sociedad o en el sector productivo.

Esta investigación es de nivel Exploratoria, Hernández y Mendoza (2018) define los estudios de alcance exploratorio como investigación de fenómenos o problemas de los cuales se tiene dudas o no se han abordado para el contexto de la investigación, se identifican conceptos, variables e hipótesis, se prepara el terreno para estudios más amplios y se propone una perspectiva innovadora.

3.2. Ámbito temporal y espacial

Esta investigación se realizó en el año 2024 con los datos recolectados en el proyecto titulado *Desarrollo de un software de machine learning para percibir los micro sueños en los choferes interprovinciales del departamento de Moquegua 2023.*

3.3. Diseño de investigación

Estudio de intervención cuasi experimental, se utiliza cuando el investigador manipula la variable independiente, pero no tiene el control total sobre la asignación aleatoria de los participantes a los grupos de estudio. En este caso, el fenómeno es observado en su contexto natural, no se realiza una asignación al azar de los sujetos de estudio y no se modificarán las condiciones naturales externas que afectan el resultado (Agudelo y Aigneren, 2018).

Este enfoque permitió aprovechar al máximo los recursos disponibles en el *Desarrollo de un software de machine learning para percibir los micro sueños en los choferes interprovinciales del departamento de Moquegua 2023,* garantizando que los videos en bruto se transformen en un dataset robusto, estructurado y preparado para cumplir con los objetivos del proyecto.

3.4. Población y muestra

3.4.1. Población.

La población es un conjunto de casos que se tomaran como referencia para definir la muestra en base a los criterios predeterminados. Este no se refiere exclusivamente a seres humano puesto que puede estar conformada por animales, muestras biológicas, expedientes, etc. Según la investigación realizada (Arias-Gómez et al., 2016).

Esta proviene de un proyecto titulado *Desarrollo de un software de machine learning para percibir los micro sueños en los choferes interprovinciales del departamento de Moquegua 2023* en este proyecto se cuenta con más de 31 videos de conductores interprovinciales que se tomaran como la población de este plan de tesis (Morales Gonzales et al., 2024).

3.4.2. Muestra

El muestreo es el proceso por el cual se selecciona un conjunto de individuos de la población con el fin de poder estudiar y caracterizar a la población.

Se optó por un muestreo no probabilístico porque esta se basa en el juicio personal del investigador para elegir los elementos que pertenecerán a la muestra, este será un muestreo intencional o de conveniencia puesto que nos permite elegir los elementos más convenientes para desarrollar la investigación de manera más sencilla (Vazquez Martinez, 2017).

En este proyecto se usó el 100% de la población disponible ya que al contar con un mayor volumen de datos permite analizar y evaluar la eficiencia del modelo, así como analizar la factibilidad de utilizarlo para el seguimiento del iris.

Se cuenta con más de 31 videos de aproximadamente una hora de duración por video obteniendo así 31 horas, 24 minutos, con 47 segundos de grabación que equivalen a más de trescientos GB de almacenamiento.

3.5. Instrumentos

3.5.1. Técnicas de recolección de información

Estos son mecanismos que se usan para reunir de forma organizada, existen 3 tipos de técnicas de recolección de datos: cualitativas, cuantitativas y mixtas, estas recopilan información, numérica, información sobre el contexto y características de fenómenos sociales o ambas respectivamente (Caro, 2021).

Se usaron técnicas de observación directa, documentos y registros para recolectar datos ya que estas nos dejan visualizar el contexto real en el que se encuentran los sujetos observados y la información ya documentada como: papers, bases de datos informes y registros.

3.5.2. Herramientas de software

- Python: Es un lenguaje de programación interpretado, de alto nivel y de propósito general. Destaca por su sintaxis clara y sencilla, lo que facilita su aprendizaje y comprensión, siendo una opción ideal tanto para quienes comienzan a programar como para desarrolladores con experiencia.
- Visual Studio Code: Editor de código fuente desarrollado por Microsoft utilizado por programadores y desarrolladores para escribir y editar código en una variedad de lenguajes de programación, como Python, JavaScript, C++, entre otros.
- Pandas: Biblioteca de Python especializada en la manipulación y análisis de datos. Proporciona estructuras de datos flexibles y potentes, como DataFrames, que facilitan la limpieza, transformación y exploración de grandes volúmenes de información de manera eficiente.
- NumPy: Biblioteca fundamental para el cálculo numérico en Python. Ofrece soporte para arrays multidimensionales y funciones matemáticas optimizadas, lo que permite realizar operaciones avanzadas con alta eficiencia y rendimiento.
- Mediapipe: Marco de trabajo desarrollado por Google para la visión por computadora y el procesamiento de datos en tiempo real. Destaca por su

capacidad de detectar y rastrear características faciales, como puntos de referencia en el rostro, con alta precisión y eficiencia.

- OpenCV: Biblioteca de código abierto ampliamente utilizada para el procesamiento de imágenes y visión por computadora. Ofrece herramientas avanzadas para la detección de objetos, reconocimiento de patrones y análisis de video, lo que la hace ideal para aplicaciones en inteligencia artificial y machine learning.

3.6. Procedimientos

Esta investigación se desarrolló en cinco fases, desarrolladas de manera secuencial, pero con un enfoque iterativo que permite mejorar continuamente el modelo de detección de distracción en conductores. Este enfoque garantiza la precisión y confiabilidad del sistema antes de su implementación en un entorno real.

Esta metodología implica la generación de datos a través de la planificación y ejecución de experimentos controlados o la observación directa de fenómenos en entornos naturales o controlados (Flores-Monroy et al., 2023).

3.6.1. Fase 1 obtención de la información

En esta fase se llevó a cabo la recopilación de datos fundamentales para el desarrollo del proyecto, abarcando tanto información teórica como material audiovisual necesario para el análisis. El objetivo principal es reunir todos los recursos que permitan comprender y modelar el comportamiento del iris en la detección de distracciones.

La investigación de Armando & Flores (2024) enfatizó la importancia de la recopilación de datos haciendo uso de los conjuntos de datos BIWI y AFLW2000. En contraste, en el presente estudio se dispone de datos obtenidos directamente de un proyecto, extraídos en su estado natural, lo que permite un enfoque más representativo de las condiciones reales.

Recopilación de videos.

Se cuenta con videos brindados por el proyecto *Desarrollo de un software de machine learning para percibir los micro sueños en los choferes interprovinciales del departamento de Moquegua 2023* los cuales cuentan con grabación frontales de todo el transcurso de viaje interprovincial en el trayecto Moquegua a Ilo, se grabaron con la finalidad de observar las acciones de los conductores en su estado natural para ser analizados.

Se cuenta con videos de más de veinte conductores y en cada uno se puede identificar diferentes conductas y acciones que realizan mediante su viaje, así como las condiciones en las que trabajan.

Consideraciones sobre el ojo humanos

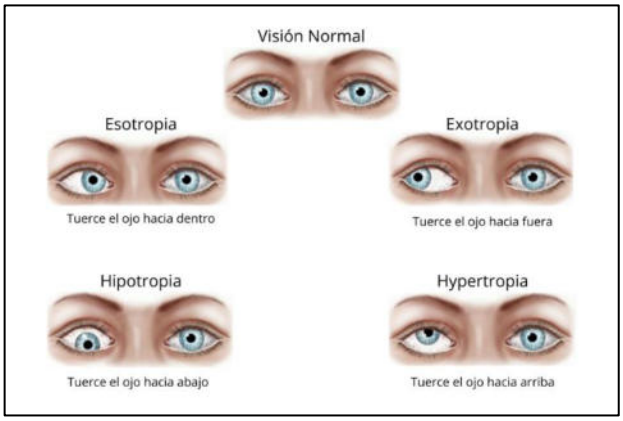
Puesto que este proyecto se centró en la detección y análisis de las facciones del ojo humanos se recopilo información relevante sobre este mismo.

El globo ocular humano tiene un diámetro aproximado de 24 milímetros en adultos, con ligeras variaciones individuales. Este tamaño es fundamental para el enfoque adecuado de las imágenes en la retina (Martínez Rodríguez & Maldonado Rivera, 2024).

El tiempo de reacción visual, definido como el intervalo entre la percepción de un estímulo visual y la respuesta motora correspondiente, varía según diversos factores, incluyendo la intensidad del estímulo y el estado de alerta del individuo. En promedio, este tiempo oscila entre 200 y 250 milisegundos (Martínez Rodríguez & Maldonado Rivera, 2024).

Existen varias enfermedades que pueden llegar a alterar tanto la forma como el funcionamiento normal del globo ocular, por consecuencia alterar la información recopilada, de las más conocidas es el estrabismo que es un trastorno ocular en el cual se pierde el paralelismo en los ejes oculares produciéndose una desviación ocular y una alteración sensorial de la visión (Pérez Barreto, 2011).

Ilustración 4
Variación de la condición de estrabismo



Fuente: Imagen referencial de variantes del estrabismo

3.6.2. Fase 2 Preprocesamiento de los datos

Esta fase se basó en la preparación y limpieza de los videos recopilados para garantizar su calidad y compatibilidad con el sistema de procesamiento. El preprocesamiento es una fase crítica, ya que permite optimizar el rendimiento del modelo de análisis y asegurar la validez de los datos.

El estudio de Villán et al. (2017) destacó la importancia de la anotación precisa de datos para entrenar modelos que detecten la somnolencia y distracción en conductores, así como el uso de algoritmos de visión por computadora para extraer características relevantes dependiendo de la investigación, como la relación de aspecto del ojo (EAR), ángulos de la cabeza y patrones de parpadeo.

Estos videos están en formato mp4, de tamaño 1920 x 1080 grabado a 29,96 fotogramas por segundo y se grabaron con la finalidad de observar las acciones de los conductores en su estado natural para ser analizados.

Tabla 1

Características de videos

Formato del video	Ancho de fotograma	Alto de fotograma	Velocidad de datos	Velocidad de fotogramas
Mp4	1920	1080	20002 kbps	30.01 fotogramas/segundo

Para el análisis se está considerando los videos donde se tenga una mayor visibilidad de rostro de la persona, sean videos de una duración extensa y donde pueda identificarse correctamente las facciones de los conductores.

Se encontraros tres situaciones que perjudican a la detección de los rostros en estos videos:

Los conductores con accesorios en el rostro: Se visualiza conductores con accesorios como gafas de sol o lentes oftálmicos, estos lentes con prescripción médica, aunque aún permiten la visualización del globo ocular el reflejo de los rayos solares perturba la detección y evita un análisis fluido y estable.

Ilustración 5

Conductor con accesorios en el rostro



Fuente: Desarrollo de un software de machine learning para percibir los micro sueños en los choferes interprovinciales del departamento de Moquegua 2023

Conductores con condiciones especiales: Se considera a los conductores que padecen condiciones médicas que puedan alterar la detección como estrabismo o miopía.

Ilustración 6
Conductor con condiciones especiales



Fuente: Desarrollo de un software de machine learning para percibir los micro sueños en los choferes interprovinciales del departamento de Moquegua 2023

Irregularidad en el video: Se encontró secciones del video donde el conductor no figura o es otra persona la que está siendo detectada, por lo cual podemos considerar estos momentos de tiempo como inválidos y eliminarlos para poder.

Ilustración 7
Irregularidades en videos



Fuente: Desarrollo de un software de machine learning para percibir los micro sueños en los choferes interprovinciales del departamento de Moquegua 2023

Se reviso detalladamente estos videos previniendo y evitando usar los videos no aptos que podrían perjudicar el análisis concreto de los resultados.

3.6.3. Fase 3 Modelo de detección

En esta fase, se emplearon modelos avanzados de visión por computadora, como MediaPipe Face Mesh y Bazeface, para analizar los videos recopilados y extraer los datos necesarios en formato CSV. El objetivo es estructurar la información relevante para su posterior procesamiento y modelado en la detección de distracciones en conductores.

MediaPipe es un modelo de aprendizaje automático diseñado para detectar y seguir en tiempo real los puntos de referencia del iris, la pupila y los contornos oculares, utilizando únicamente una cámara RGB y sin requerir hardware especializado (Vakunov & Lagun, 2020).

Media pipe Face Mesh es una solución de geometría de caras que permite obtener 468 puntos clave en tiempo real mediante la aplicación de modelos en machine learning. Este mismo emplea dos modelos de Redes Neuronales Profundas que trabajan simultáneamente las cuales se encargan de la detección facial en la

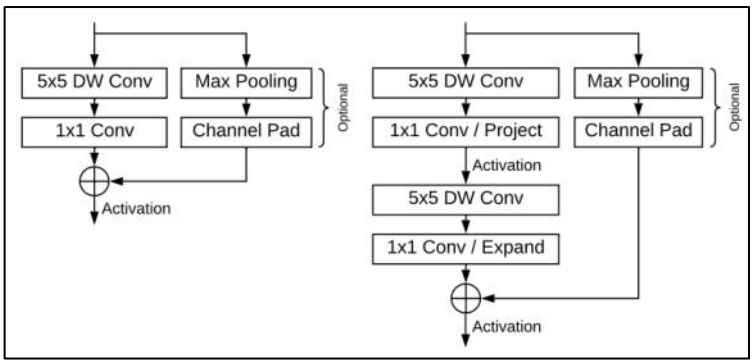
información brindada y la colocación de la malla facial referente a los puntos brindados por el primer modelo.

Face detection model

Face detection model opera sobre toda la imagen para obtener los lugares donde están presentes los rostros, además produce coordenadas de los seis puntos claves en el rostro detectado.

Esta solución se basa en BlazeFace el cual está diseñado para integrarse en aplicaciones de realidad aumentada que requieren detección precisa y rápida de rostros. Además de identificar la posición del rostro, el modelo predice seis puntos clave faciales: centros de los ojos, trágicos de las orejas, centro de la boca y punta de la nariz. Estos puntos permiten estimar la rotación del rostro, facilitando el procesamiento posterior en tareas específicas como estimación de geometría facial o clasificación de expresiones.

Ilustración 8
Single BlazeBlock y Double BlazeBlock



Fuente: BlazeFace: Sub-millisecond Neural Face Detection on Mobile GPUs

Cabe resaltar que utiliza la convolución en profundidad para su tiempo de ejecución y eficiencia en términos computacionales, así como la convolución 1x1 que, aunque más lenta, permite mesclar la información en diferentes canales y así reducir o expandir el número de canales en la red (Bazarevsky et al., 2019).

Para su extracción de características toma una entrada RGB de 128 x 128 pixeles y consta de una convolución 2D seguidas de cinco BlazeBlocks simples y

seis BlazeBlocks dobles con una profundidad de 96 canales, gracias a esto está optimizado para ser rápido y eficiente, especialmente en dispositivos móviles generando menos anclajes, lo que reduce la carga computacional.

Tabla 2
Arquitectura de red de extracción de características

Layer/Block	Input Size	Conv. Kernel Sizes
Convolution	128 X 128 X 3	5 X 5 X3 X 24 (stride 2)
Single BlazeBlock	64 X 64 X 24	5 X 5 X 24 X 1
		1 X 1 X 24 X 24
Single BlazeBlock	64 X 64 X 24	5 X 5 X 24 X 1
		1 X 1 X 24 X 24
Single BlazeBlock	64 X 64 X 24	5 X 5 X 24 X 1 (stride 2)
		1 X 1 X 24 X 48
Single BlazeBlock	32 X 32 X 48	5 X 5 X 24 X 1
		1 X 1 X 24 X 48
Single BlazeBlock	32 X 32 X 48	5 X 5 X 24 X 1
		1 X 1 X 24 X 48
Double BlazeBlock	32 X 32 X 48	5 X 5 X 48 X 1 (stride 2)
		1 X 1 X 48 X 24
		5 X 5 X 24 X 1
		1 X 1 X 24 X 96
Double BlazeBlock	16 X 16 X 96	5 X 5 X 96 X 1
		1 X 1 X 96 X 24
		5 X 5 X 24 X 1
		1 X 1 X 24 X 96
Double BlazeBlock	16 X 16 X 96	5 X 5 X 96 X 1
		1 X 1 X 96 X 24
		5 X 5 X 24 X 1
		1 X 1 X 24 X 96
Double BlazeBlock	16 X 16 X 96	5 X 5 X 96 X 1 (stride 2)
		1 X 1 X 96 X 24
		5 X 5 X 24 X 1
		1 X 1 X 24 X 96
Double BlazeBlock	8 X 8 X 96	5 X 5 X 96 X 1

Esta tabla continua

		1 X 1 X 96 X 24
		5 X 5 X 24 X 1
		1 X 1 X 24 X 96
Double BlazeBlock	8 X 8 X 96	5 X 5 X 96 X 1
		1 X 1 X 96 X 24
		5 X 5 X 24 X 1
		1 X 1 X 24 X 96

El resultado de esta detección nos brinda la ubicación en la que se encuentra el rostro y 6 puntos referenciales

Tabla 3
Puntos referenciales extraídos

RIGHT EYE	LEFT EYE	NOSE TIP	MOUTH CENTER	RIGT EAR TRAGION	LEFT EAR TRAGION
Ojo derecho	Ojo Izquierdo	Punta de la nariz	Centro de la boca	Trago de la oreja derecha	Trago de la oreja izquierda

Ilustración 9
Detección de rostros



Fuente: Elaboración propia

Face Landmark model

Este modelo opera sobre las ubicaciones de los rostros detectados y genera las posiciones de los rostros con una malla facial predefinida de 468 puntos para conectar los landmarks estos se posicionan en el rostro en relación a la detección previamente hecha y prediciendo la ubicación de los landmarks.

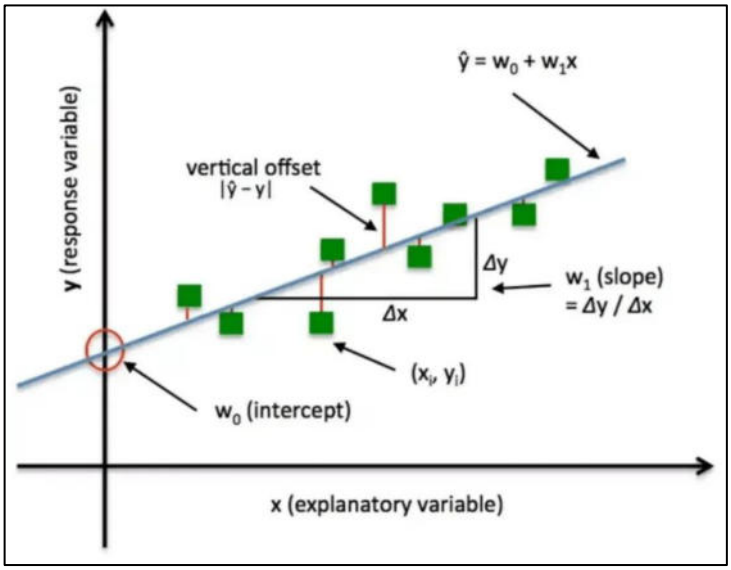
Esta malla define cómo se relacionan los puntos entre sí guiándose de la detección previa de face detection, cabe resaltar que los landmarks se van obteniendo basándose en el fotograma anterior mediante tracking o seguimiento de ellos, posteriormente se vuelve a invocar a face detection únicamente cuando no se logró identificar la presencia del rostro (Lugaresi et al., 2019).

Una vez se obtiene la ubicación del rostro mediante fase detection y se obtienen las características de la imagen el cabezal de regresión toma estas características y predice las coordenadas 3D de los 468 landmarks (Zhang et al., 2014).

El cabezal de regresión consiste en varias capas fully connected (totalmente conectadas) que mapean las características extraídas a las coordenadas 3D (x, y, z) de los landmarks. La salida de del cabezal de regresión es un vector de 1404 valores (468 landmarks × 3 coordenadas).

La función de pérdida es crucial para entrenar el modelo. En el caso del Face Landmark Model, se utiliza una función de pérdida basada en la distancia euclidiana (Bulat & Tzimiropoulos, 2017).

Ilustración 10
Expresión referencial de Loss Function



Fuente: *referencial de Loss Function*

$$Loss\ Fuction = (yi - \hat{y})^2$$

$$Cost\ Function\ J(b_0, b_1) = \frac{1}{2n}\sum_{i=1}^{n}(y_i - \hat{y})^2$$

$$= \frac{1}{2n}\sum_{i=1}^{n}(y_i - b_0 - b_1 x_i)^2$$

Este modelo contiene 1700 muestras, cien de cada una de las 17 subregiones geográficas, que fueron anotadas con género percibido (masculino y femenino) y tono de piel (de uno a seis) según la escala de Fitzpatrick.

Se muestra los resultados de la detección basado en *Main mode* conocido como modo principal que tiene lugar la mayor parte del tiempo y se basa en la obtención de un recorte de rostro altamente preciso a partir de la predicción en el fotograma anterior (fotogramas 2, 3, ... en la imagen siguiente) y el *Reacquisition mode* que se produce cuando no hay información sobre el rostro de los fotogramas anteriores. Ocurre en el primer fotograma (imagen siguiente) o en los fotogramas en los que se pierde el seguimiento del rostro. En este caso, se ejecuta BlazeFace Detector para evaluar el modo de readquisición (Yan & Ivan Grishchenko, 2022).

Tabla 4
Evaluación por genero

Gender	Tracking mode (primary)			Reacquisition mode (on the first frame)		
	% of dataset	Mean absolute error	Standard deviation	% of dataset	Mean absolute error	Standard deviation
Male	46,5%	2,61	1,03	46,6%	3,25	1,34
Female	53,5%	2,62	1,04	53,4%	3,24	1,24

Tabla 5
Evaluación por tono de piel

Skin Tone Type	Tracking mode (primary)			Reacquisition mode (on the first frame)		
	% of dataset	Mean absolute error	Standard deviation	% of dataset	Mean absolute error	Standard deviation
1	1,5%	2,90	1,51	1,5%	3,75	2,13
2	14,8%	2,64	1,00	14,7%	3,27	1,21
3	34,5%	2,68	1,03	34,6%	3,33	1,33
4	28,6%	2,55	0,93	28,6%	3,13	1,11
5	14,4%	2,49	1,04	14,4%	3,09	1,24
6	6,3%	2,77	1,34	6,1%	3,48	1,68

Una vez el seguimiento del iris está en funcionamiento se realizó la detección de las distracciones, puesto que el punto 468 y 473 detectan el centro de la pupila del globo ocular se utilizarán para medir la distancia entre el borde externo e interno del ojo, además descubrir cuanta distancia hay entre pupila y bordes del ojo nos ayudara a saber el porcentaje de espacio que se moviliza la pupila al mirar a una dirección u otra.

Se usó la distancia euclidiana para hallar una medida manejable en la cual realizar estas pruebas.

$$D = \sqrt{(x_0 - x_1)^2 + (y_0 - y_1)^2}$$

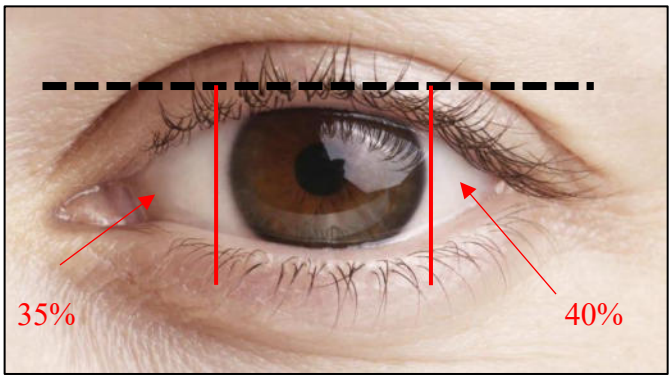
Se realizó las pruebas primero extrayendo un promedio de la media de distancias de videos donde se observa en dirección izquierda, dirección derecha y centro, con esto y según los resultados se estimó que las distancias en las cuales se ubica la pupila en cada dirección varían del 35 al 40 % de espacio del globo ocular, esto dependiendo de la distancia de la cámara, la orientación o incluso el ojo que se utiliza para la detección.

Tabla 6
Resultados de zona de detección

Distancia promedio		
Extremo a extremo	**Borde interno a pupila**	**Borde externo a pupila**
87,143	32,254	37,676
100 %	37,012 %	43,234 %

Una vez el algoritmo esta calibrado se tomó la decisión que por la orientación de los videos y la posición de la cámara tomar como punto de detección al globo ocular derecho puesto que es más visible y presta una mejor precisión en la detección para lo que se usó un espacio del ojo del 40% hacia la derecha y un 35% hacia la izquierda, esto dependiendo de la distancia entre los extremos del ojo derecho.

Ilustración 11
División de las zonas de detección



Fuente: Optometría comportamental – terapia visual

Para la construcción del dataset se extrajeron los datos de la posición de las pupilas, así como la distancia de bordes del ojo a detectar y la distancia de bordes a la pupila de cada ojo.

Se evaluaron cada uno de los frames de los videos y así detectar el movimiento de los ojos en cada momento del video, también dependiendo del cálculo de la distancia euclidiana se colocará una etiqueta que indica a que dirección está viendo la persona.

Ilustración 12

Resultados de evaluación de frames

Frame Numbe	Left Pupil X	Left Pupil Y	Right Pupil X	Right Pupil Y	Distance Oute	Distance Pupi	Distance Pupi	Distance Pupi	Distance Pupi	Direction
0	553	1001	754	983	66.0984115	42.2018957	48.0104155	23.0217289	43.9658959	DERECHA
1	538	999	740	984	68.8839604	44.1474801	48.0104155	23	46.3249393	DERECHA
2	521	997	725	983	69.7208721	42.2018957	49.0407993	21.023796	49.244289	DERECHA
3	504	996	708	983	68.7313611	41.2310563	47.0425339	19.0262976	49.8196748	DERECHA
4	486	995	685	983	70.4556598	46.8721666	42.0475921	23.0217289	47.8539445	DERECHA
5	468	993	669	983	69.7208721	46.0977223	42.1070065	20.0249844	49.8196748	DERECHA
6	449	989	650	981	70.3491293	46.3249393	44.1021541	20	50.4876222	DERECHA
7	434	985	634	978	71.3442359	48.0520551	40.1123422	21.023796	50.6359556	DERECHA
8	412	985	618	976	72.2495675	41	50.039984	21.2132034	51.7880295	DERECHA
9	393	987	592	976	70.0071425	53.2353266	44.0113622	27.1661554	43.1856458	DERECHA
10	363	980	568	971	79.0253124	47.2652092	50	37.1214224	42.296572	CENTRO
11	332	966	556	958	77.1038261	34.3656806	58.0775344	33.7342556	45.3541619	CENTRO
12	320	955	547	952	81.1541743	30.8058436	61.4003257	36.3455637	46.0977223	CENTRO
13	321	951	545	949	88.0511215	35.6931366	52.6117858	38.3275358	50.6359556	CENTRO
14	318	948	546	947	90.0055554	33.5410197	56.4358042	39.6232255	51.623638	CENTRO
15	320	949	552	948	88.0056816	32.7566787	57.4282161	36.4965752	52.4690385	CENTRO
16	322	950	554	948	89.0224691	31.5753068	58.2151183	37.3363094	52.4690385	CENTRO
17	327	955	556	953	92.0489	32.0156212	55.3263048	38.3275358	54.5893763	CENTRO

Fuente: Elaboración propia

Estos datos obtenidos nos permitieron analizar detenidamente cada momento en el cual se detecta una fluctuación en la detección dependiendo si hay movimiento irregular en los ojos, fallo en la detección u distracciones prolongadas en el transcurso del viaje.

3.6.4. Fase 4 Evaluación de resultados

En esta etapa, se realizó un análisis exhaustivo para determinar si los resultados obtenidos cumplen con los objetivos establecidos. Se verifica la precisión y relevancia de los parámetros extraídos, asegurando que sean adecuados para la aplicación prevista. Además, se evalúa la fiabilidad del sistema considerando su desempeño, con el fin de determinar su viabilidad para su implementación en un prototipo funcional.

Al revisar los datos obtenido se ven irregularidades en el conteo de frames y variación tanto en la posición de detección de la pupila como en la posición en la que se ubica, al revisar detenidamente estas situaciones resulta que en algunos momentos el conductor no está presente en la detección y usan accesorios que evitan una detección fluida por lo cual sucede la variación en la posición y el fallo en el conteo de los frames.

Para esto se decidió cortar ciertas partes de lo ya detectado en el dataset para al momento de analizar los datos estos puedan exponer una perspectiva más fiable y conocer la efectividad de este modelo.

Se usaron métricas de medición estadística para evaluar los datos recogidos y poder expresarlos en una tabla donde también se almacena el conteo de distracción según lo prolongadas que sean.

Media (Promedio)

La media aritmética es una medida de tendencia central que se obtiene sumando todos los valores de un conjunto de datos y dividiéndolos entre el número total de observaciones, proporciona una idea del valor central o típico de los datos. Sin embargo, es sensible a valores atípicos o extremos.

En el estudio de Díaz-Chang & Arredondo (2022) se observó un incremento en los valores medios de tiempos de resolución de cada ítem a medida que avanzaba el test, acompañado de una mayor dispersión, lo cual podría indicar fatiga atencional.

Si este valor cambia mucho entre distintos videos, puede significar que la posición del ojo varía dependiendo del usuario o las condiciones de grabación. En términos prácticos, este número es una referencia base sobre dónde suele ubicarse el iris en los fotogramas.

$$\bar{X}=\frac{1}{N}\sum_{i=1}^{N} X_i$$

Desviación Estándar

La desviación estándar mide la dispersión o variabilidad de un conjunto de datos respecto a su media. Indica cuánto se alejan, en promedio, los valores individuales de la media del conjunto.

Si la desviación estándar es muy alta, indica que la detección no es estable y cambia mucho entre cuadros. Un valor moderado puede deberse a movimientos naturales del ojo.

$$\sigma = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(X_i - \bar{X})^2}$$

Coeficiente de Variación (CV)

El coeficiente de variación es una medida de dispersión relativa que expresa la desviación estándar como un porcentaje de la media. Es útil para comparar la variabilidad entre conjuntos de datos con diferentes unidades o medias.

En el estudio de Salazar Olarte (2021) se presentan promedios y coeficientes de variación de las respuestas obtenidas, lo que permite establecer coincidencias entre respuestas verbales y fijaciones o diámetros de la pupila.

Un CV más bajo indica menor variabilidad relativa, mientras que un CV más alto señala mayor dispersión en relación con la media. Teniendo en cuenta las condiciones a las que se sujeta esta medida se puede interpretar la confiabilidad y fluctuación en relación a la media:

CV < 0.1 (10%) → Baja variabilidad, buena precisión.

CV entre 0.1 y 0.3 → Variabilidad moderada.

CV > 0.3 → Alta variabilidad, posible inestabilidad en la detección.

$$CV = \frac{\sigma}{\bar{X}}$$

Media de Diferencias Absolutas (MAD)

La media de las diferencias absolutas mide la variabilidad promedio entre valores consecutivos en un conjunto de datos. Indica la magnitud promedio de los cambios entre observaciones sucesivas.

Aunque no se menciona específicamente la MAD en los estudios encontrados, esta métrica es comúnmente utilizada en el análisis de series temporales para evaluar la variabilidad entre observaciones consecutivas, lo cual es relevante en el seguimiento ocular (Mauricio, 2013).

Si este valor fuera muy alto (por ejemplo, >10 píxeles), indicaría que la detección de la pupila es inestable y salta demasiado, un valor bajo sugiere que la detección es suave y sin cambios bruscos.

$$MAD = \frac{1}{N-1}\sum_{i=1}^{N-1}|X_{i+1} - X_i|$$

Índice de Estabilidad (EI)

El índice de estabilidad es una medida compuesta que evalúa la consistencia de un conjunto de datos, considerando tanto la variabilidad relativa (CV) como la variabilidad entre observaciones consecutivas (MAD).

En el análisis de series temporales, la estabilidad de los datos es crucial para la predicción y el modelado. El EI puede utilizarse para evaluar la consistencia de series temporales en campos como la meteorología o las finanzas, así como en el control de calidad, métricas como el CV y la MAD se utilizan para evaluar la consistencia de los procesos de producción. El EI podría ser una extensión natural para medir la estabilidad de los datos de calidad (Montgomery & Wiley, 2010).

Un EI cercano a uno indica alta estabilidad en los datos, mientras que valores más bajos sugieren mayor inestabilidad o variabilidad.

$$EI = 1 - (CV + \frac{MAD}{\bar{X}})$$

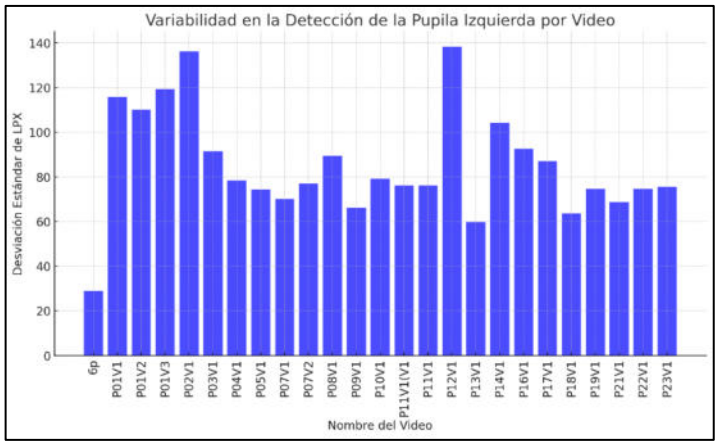
Todos estos datos se recopilan en una tabla donde se analizan estas medidas para las coordenadas x, y para cada uno de los ojos.

Tabla 7
Conjunto de datos analizados

Media		Desviación Estándar		Coeficiente De Variación		Media De Diferencia Absoluta		Índice De Estabilidad	
Ojo izquierdo	Ojo derecho	Ojo izquierdo	Ojo derecho	Ojo izquierdo	Ojo derecho	Ojo izquierdo	Ojo derecho	Ojo izquierdo	Ojo derecho
[X , Y]		[X , Y]		[X , Y]		[X , Y]		[X , Y]	

Con estos datos podemos realizar análisis más profundos, este gráfico de barras muestra la variabilidad en la detección de la pupila izquierda (LPX Desviación Estándar) para cada video. Un valor más alto indica que la detección fue menos estable en ese video.

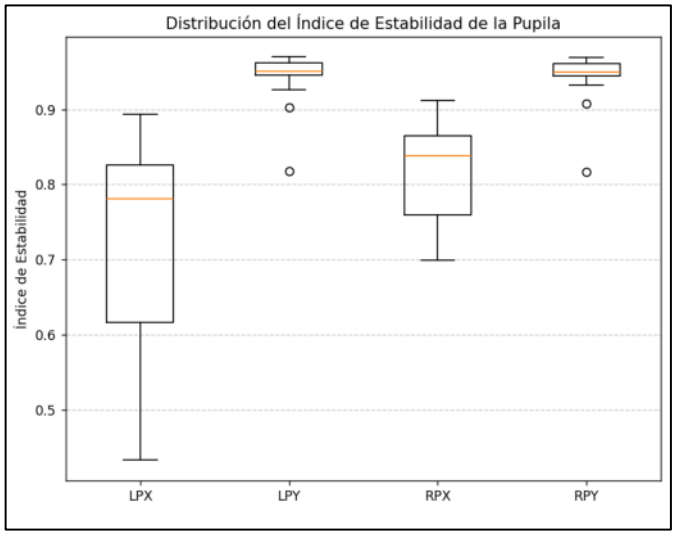
Ilustración 13
Variabilidad de la detección



Fuente: Elaboración propia

Se usó un gráfico boxplot donde se puede visualizar la estabilidad de la pupila en cada uno de los ojos, así como su promedio de ubicación más frecuente.

Ilustración 14
Distribución del índice de Estabilidad



Fuente: Elaboración propia

Adicionalmente se recopiló el tiempo total en que se detectó distracción tanto a la izquierda como a la derecha y su total equivalente en segundos de cada video para poder saber con exactitud el tiempo total invertido en distracciones durante el trayecto del viaje.

Ilustración 15
Resultados del tiempo de distracción

Nombre del \	<1s	<2s	<3s	<4s	>5s	Tiempo Derecha	Tiempo Izquierda	Tiempo Total	Minutos
P01V1	2278	15	1	0	0	111.662	51.996	163.658	3:44
P01V2	6112	48	2	1	1	264.314	231.696	496.010	8:16
P01V3	4403	43	2	0	0	192.007	136.810	328.817	5:29
P02V1	2555	6	0	0	0	71.306	67.371	138.677	2:19
P03V1	22550	173	25	6	9	92.985	1505.074	1598.059	27:38
P04V1	28062	238	33	13	5	119.200	2048.210	2167.410	36:07
P05V1	3751	4	0	0	0	39.155	91.484	130.640	2:11
P07V1	3308	6	0	0	0	19.144	144.948	164.092	3:44
P07V2	5731	22	0	0	0	64.469	293.964	358.433	6:58
P08V1	3438	1	0	0	0	66.270	144.381	210.651	4:31
P09V1	10974	7	2	0	1	248.572	229.895	478.467	8:58
P10V1	2963	37	0	0	0	128.839	156.087	284.926	5:45
P11V1	4322	32	2	0	0	110.895	183.002	293.897	5:54
P12V1	3711	8	1	1	1	164.959	37.121	202.079	3:22
P13V1	12377	7	0	0	0	301.435	148.683	450.118	8:30
P14V1	5741	34	2	0	0	84.447	291.229	375.676	6:16
P16V1	10641	45	9	1	0	538.367	37.488	575.855	10:36
P17V1	2765	38	1	0	0	107.060	136.243	243.303	4:03
P18V1	2673	4	0	0	0	29.350	123.269	152.619	3:33
P19V1	2975	24	0	0	0	112.229	155.253	267.483	4:27
P21V1	10435	55	5	0	1	529.529	47.060	576.589	10:37
P22V1	7211	20	3	0	0	159.756	183.603	343.358	6:43
P23V1	9638	31	1	0	1	211.985	294.231	506.216	8:26

Fuente: Elaboración propia

Al analizar estas medidas en las diferentes detecciones realizadas se evidenció un nivel muy elevado de la desviación estándar en algunos resultados,

esto llegas a evidenciar la variación en el espacio de detección y el margen en el que se detectó la pupila.

Ilustración 16
Irregularidades en la desviación estándar

ombre del Vide	LPX Media	Desviación Está	eficiente de Va	de Diferencias	ndice de Estabi	LPY Media
P01V1	272.975	115.854	0.424	6.057	0.554	843.366
P01V2	249.861	110.239	0.441	6.327	0.534	1020.823
P01V3	379.692	119.329	0.314	5.987	0.67	831.699
P02V1	353.058	136.341	0.386	8.192	0.591	605.899
P03V1	388.385	91.495	0.236	4.944	0.751	915.612
P04V1	147.928	78.533	0.531	5.264	0.433	1074.335
P05V1	447.382	74.357	0.166	4.482	0.824	1076.392
P07V1	350.026	70.068	0.2	4.145	0.788	1204.203
P07V2	472.894	76.973	0.163	4.25	0.828	856.89
P08V1	246.196	89.386	0.363	5.084	0.616	868.864
P09V1	428.074	66.213	0.155	8.1	0.826	1190.797
P10V1	349.579	79.178	0.226	4.326	0.762	1055.416
P11V1	428.645	76.111	0.178	4.039	0.813	1126.486
P12V1	333.089	138.276	0.415	5.588	0.568	335.501
P13V1	271.697	59.78	0.22	4.194	0.765	1178.649
P14V1	503.393	104.248	0.207	5.931	0.781	958.928
P16V1	457.941	92.643	0.202	3.075	0.791	1220.42
P17V1	276.702	87.068	0.315	4.181	0.67	1042.203
P18V1	484.029	63.646	0.131	3.267	0.862	946.761
P19V1	543.06	74.755	0.138	4.822	0.853	1041.211
P21V1	673.128	68.758	0.102	2.61	0.894	1220.841
P22V1	192.613	74.729	0.388	3.55	0.594	1140.249
P23V1	592.875	75.694	0.128	4.251	0.865	1324.685

Fuente: Elaboración propia

Por consiguiente, tanto el coeficiente de variación y la media de diferencia absoluta presentan valores elevados en relación al promedio estándar hallado en las demás detecciones como se muestra en la tabla.

Tabla 8
Análisis de los resultados de la persona 1

Nombre del Video	LPX Desviación Estándar	LPX Coeficiente de Variación	LPX Media de Diferencias Absolutas	LPX Índice de Estabilidad
P01V1	115,854	0,424	6,057	0,554
P01V2	110,239	0,441	6,327	0,534
P01V3	119,329	0,314	5,987	0,67
PROMEDIO	87,4910417	0,258	4,862	0,726

Estos resultados nos permitieron concluir que en estos análisis sucedieron irregularidades que alteraron la detección de la pupila en estos videos.

La primera persona, conjunto de videos *P01V1, P01V2, P01V3*, se comprobó que esta persona padecía de estrabismo en el ojo izquierdo, al comparar sus resultados con su ojo derecho se evidencia una gran diferencia.

Ilustración 17
Persona 1 con estrabismo



Fuente: Desarrollo de un software de machine learning para percibir los micro sueños en los choferes interprovinciales del departamento de Moquegua 2023

En el caso de la segunda persona, conjunto de videos *P02V1*, realizar diversos movimientos en todo el transcurso del video además que su rostro no permanece enfocado en la grabación por lo que causa estas irregularidades.

Ilustración 18
Irregularidades en la detección de la persona 2



Fuente: Desarrollo de un software de machine learning para percibir los micro sueños en los choferes interprovinciales del departamento de Moquegua 2023

También podemos apreciar un valor inusual en la Media de Diferencias Absolutas (MAD) de 8,1 en la persona *P09V1* lo que puede significar ruido en la detección, esto se corrobora al analizar el video del cual se extrajeron los datos.

Ilustración 19
Ruido en la detección de la persona 9



Fuente: Desarrollo de un software de machine learning para percibir los micro sueños en los choferes interprovinciales del departamento de Moquegua 2023

La cuarta persona, conjunto de videos *P04V1*, presenta un tiempo total de distracción de más de 36 minutos en total del transcurso del viaje lo cual es un

resultado inesperado puesto que representa más de la mitad el tiempo de viaje esperado.

Tabla 9
Resultados del tiempo de distracción de la persona 4

Tiempo Derecha	Tiempo Izquierda	Tiempo Total	Minutos
119,2	2048,21	2167,41	36:07:00

Al analizar con detalle esta situación se concluyó que esto sucede por el uso de lentes oftálmicos lo cual, mediante el reflejo de luz solar, interrumpe y evita una detección continua y precisa de la pupila.

Ilustración 20
Uso de lentes oftálmicos de persona 4



Fuente: Desarrollo de un software de machine learning para percibir los micro sueños en los choferes interprovinciales del departamento de Moquegua 2023

Con este análisis se logró identificar tanto las condiciones, acciones e incluso situaciones medicas en las cuales se llevan a cabo los viajes interprovinciales, presentado esta información se espera mejorar las condiciones en las que se realicen estos viajes para así brindar mayor seguridad al público en general.

3.6.5. Fase 5 Implementación

Se procedió a la integración del modelo de seguimiento del iris en el sistema de detección de somnolencia, asegurando que los datos obtenidos durante las fases previas sean precisos, confiables y representativos del fenómeno estudiado.

Se realizó el primer prototipo con el seguimiento del iris integrado bajo la estructura propuesta de MediaPipe agregando su paquete de modelos *FaceLandmarker.task*.

Ilustración 21
Implementación de MediaPipe "face_landmarker.task

```
# Create a face landmarker instance with the video mode:
options = FaceLandmarkerOptions(
    base_options=BaseOptions(
        model_asset_path='model/face_landmarker.task'),
    running_mode=VisionRunningMode.VIDEO
    )
self._facelandmark_detector = FaceLandmarker.create_from_options(options)
self._drowsiness_detector = DrowsinessDetector(DrowsinessParameters(2, 0.5, 0.4, 1.5))
self._distraction_detector = distractionDetector()
self._drowsiness_alarm = DrowsinessAlarm()
```

Fuente: Elaboración propia

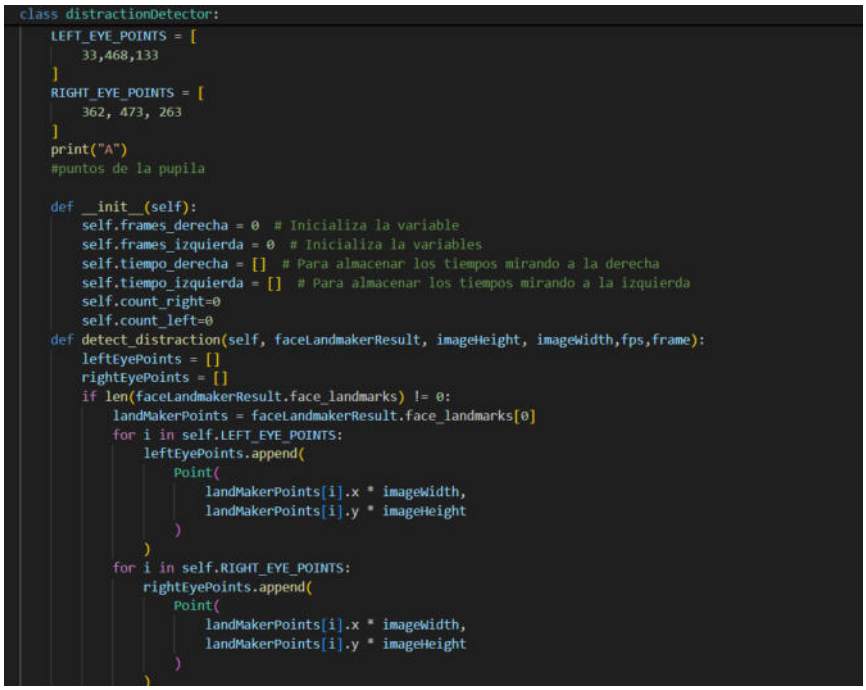
Se añadió una nueva clase *distractionDetector* para poder añadir el detector de distracciones sin alterar la composición de la detección de la somnolencia del modelo. En esta clase se trabaja con los puntos:

LEFT_EYE_POINTS = [33,468,133]

RIGHT_EYE_POINTS = [362, 473, 263]

Estos puntos nos permitieron identificar tanto el borde interno como externo y la pupila de cada uno de los ojos.

Ilustración 22
Class distractionDetector



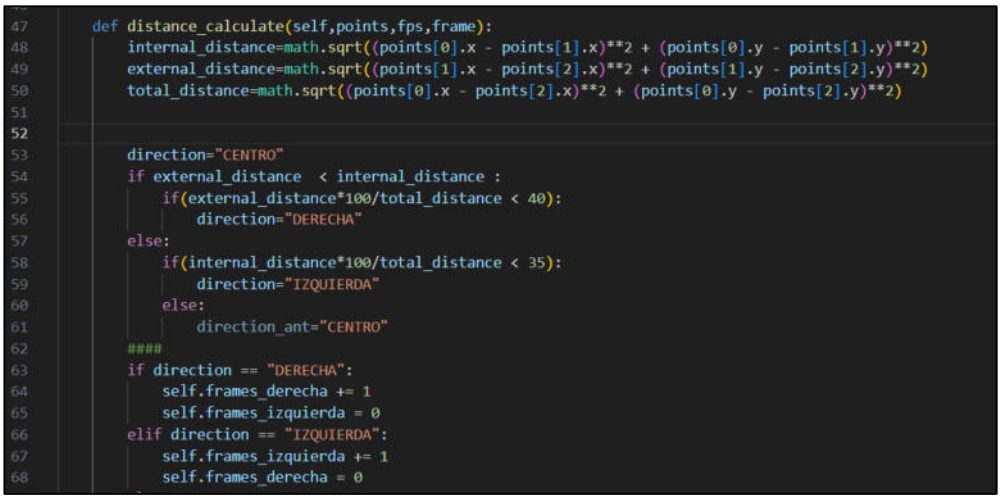
```
class distractionDetector:
    LEFT_EYE_POINTS = [
        33,468,133
    ]
    RIGHT_EYE_POINTS = [
        362, 473, 263
    ]
    print("A")
    #puntos de la pupila

    def __init__(self):
        self.frames_derecha = 0  # Inicializa la variable
        self.frames_izquierda = 0  # Inicializa la variables
        self.tiempo_derecha = []  # Para almacenar los tiempos mirando a la derecha
        self.tiempo_izquierda = []  # Para almacenar los tiempos mirando a la izquierda
        self.count_right=0
        self.count_left=0
    def detect_distraction(self, faceLandmakerResult, imageHeight, imageWidth,fps,frame):
        leftEyePoints = []
        rightEyePoints = []
        if len(faceLandmakerResult.face_landmarks) != 0:
            landMakerPoints = faceLandmakerResult.face_landmarks[0]
            for i in self.LEFT_EYE_POINTS:
                leftEyePoints.append(
                    Point(
                        landMakerPoints[i].x * imageWidth,
                        landMakerPoints[i].y * imageHeight
                    )
                )
            for i in self.RIGHT_EYE_POINTS:
                rightEyePoints.append(
                    Point(
                        landMakerPoints[i].x * imageWidth,
                        landMakerPoints[i].y * imageHeight
                    )
                )
```

Fuente: Elaboración propia

Se agregó la función *distance_calculate* que permite conocer la distancia entre los puntos para posteriormente hacer el conteo del tiempo de distracción en cada frame del video.

Ilustración 23
Función distance_calculate



```
47      def distance_calculate(self,points,fps,frame):
48          internal_distance=math.sqrt((points[0].x - points[1].x)**2 + (points[0].y - points[1].y)**2)
49          external_distance=math.sqrt((points[1].x - points[2].x)**2 + (points[1].y - points[2].y)**2)
50          total_distance=math.sqrt((points[0].x - points[2].x)**2 + (points[0].y - points[2].y)**2)
51
52
53          direction="CENTRO"
54          if external_distance  < internal_distance :
55              if(external_distance*100/total_distance < 40):
56                  direction="DERECHA"
57          else:
58              if(internal_distance*100/total_distance < 35):
59                  direction="IZQUIERDA"
60              else:
61                  direction_ant="CENTRO"
62          ####
63          if direction == "DERECHA":
64              self.frames_derecha += 1
65              self.frames_izquierda = 0
66          elif direction == "IZQUIERDA":
67              self.frames_izquierda += 1
68              self.frames_derecha = 0
```

Fuente: Elaboración propia

Con esto añadido se realizó la detección de la distracción y detección de la somnolencia. Ahora se puede identificar estos factores con más precisión y poder analizarlos.

Ilustración 24

Detección de la distracción izquierda y derecha



Fuente: Elaboración propia

Ilustración 25

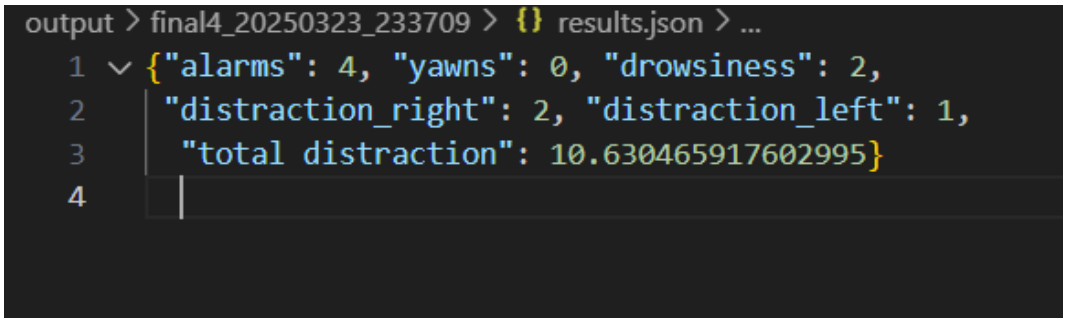
Detección de somnolencia micro sueño y bostezo



Fuente: Elaboración propia

Este prototipo nos permitió guardar la información de las veces en las que se detectó una distracción, así como el conteo del monitoreo de somnolencia y el tiempo total que duro las distracciones en un archivo *JSON*.

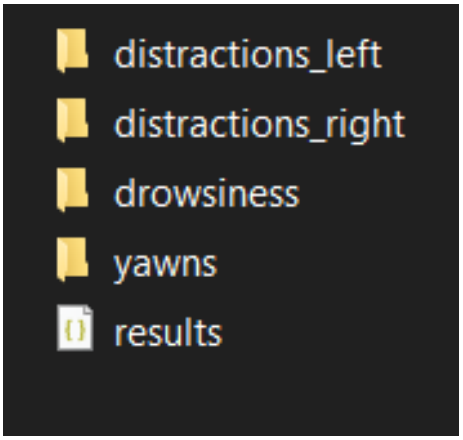
Ilustración 26
Conteo de distracciones y monitoreo de somnolencia



Fuente: Elaboración propia

Así como guardar una imagen referencial de cuando se activó la alarma de distracción o detección de somnolencia.

Ilustración 27
Archivos de almacenamiento de alarma



Fuente: Elaboración propia

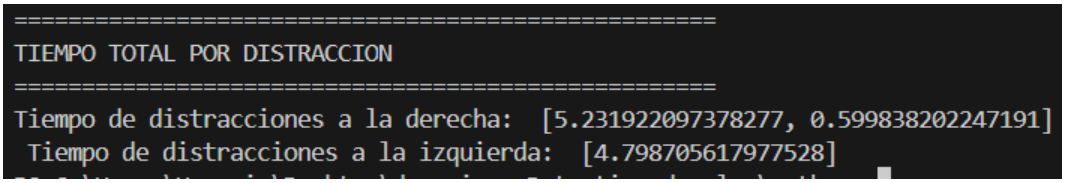
Ilustración 28
Alarmas mostradas



Fuente: Elaboración propia

También nos muestra todas las detecciones y el tiempo invertido en cada una como referencia en la consola.

Ilustración 29
Tiempo total por distracciones



Fuente: Elaboración propia

Como podemos ver este prototipo provee una detección muy precisa y fiable tanto de las distracciones como de las señales de somnolencia.

3.7. Análisis de datos

El análisis se centró en evaluar y validar las dos fases del modelo utilizado, tanto la detección facial como el modelo de malla facial para la detección de la pupila.

- **Python:** Se realizaron pruebas exhaustivas del código desarrollado en Python para garantizar la correcta implementación del modelo de inteligencia artificial. La validación de este instrumento se llevó a cabo

mediante pruebas unitarias y de integración, verificando su precisión en la detección del movimiento ocular

- **Visual Studio Code:** La confiabilidad de este entorno de desarrollo se garantizó mediante su amplia adopción en la comunidad de programación y su capacidad para soportar la integración de herramientas de control de versiones (Git) y depuración.

Estas metodologías y técnicas se fundamentan en la reducción de datos, su representación y la etapa de conclusiones y verificación. Este proceso puede realizarse tanto antes de la recolección de datos, durante los análisis iniciales, como después, al elaborar el producto final (Denman & Haro, 2002).

- **Tablas:** Se emplearon tablas para mostrar las características extraídas de la base de datos de la población que se usara para este proyecto.
- **Gráficos de Barras y Columnas** Se utilizaron para representar los datos a evaluar e identificar los picos más altos de los datos.
- **Diagramas boxplot** Con él se visualizaron los datos en un plano lo que permitió representar la distribución de un conjunto de datos.

IV. Resultados y discusión

4.1. Resultados

Los resultados obtenidos reflejaron fielmente la información capturada en los videos de origen, lo que demuestra la eficacia del modelo de inteligencia artificial desarrollado para el seguimiento del iris en conductores de transporte interprovincial. A partir de la aplicación del modelo de MediaPipe, se logró detectar y monitorear con precisión los puntos de referencia en los ojos, incluyendo los puntos de la pupila y los más alejados de cada ojo. Asimismo, la medición de la distancia entre los puntos permitió determinar la dirección de la mirada, lo que posibilitó la identificación de distracciones en los conductores.

Al recopilar toda esta información obtuvimos el porcentaje de detección fiel en cada uno de los videos, en promedio de todos los videos es un 93% de detección fiable y precisa además de que se obtuvo un 11,42% de distracción total según el trayecto recorrido, aproximadamente de siete a ocho minutos, aunque estos valores sean menores aun podemos apreciar falencias en la detección como un 78,89% cuando el conductor presenta actitudes y movimientos bruscos mediante su monitoreo.

Ilustración 30
% Distracción y % Detección



Fuente: Elaboración propia

Tabla 10
Resultados de investigación

RESULTADOS DE INVESTIGACION			
Tiempo Total	**Minutos**	**% Distracción**	**% Detección**
456.83	00:07:37	11,42	93,00

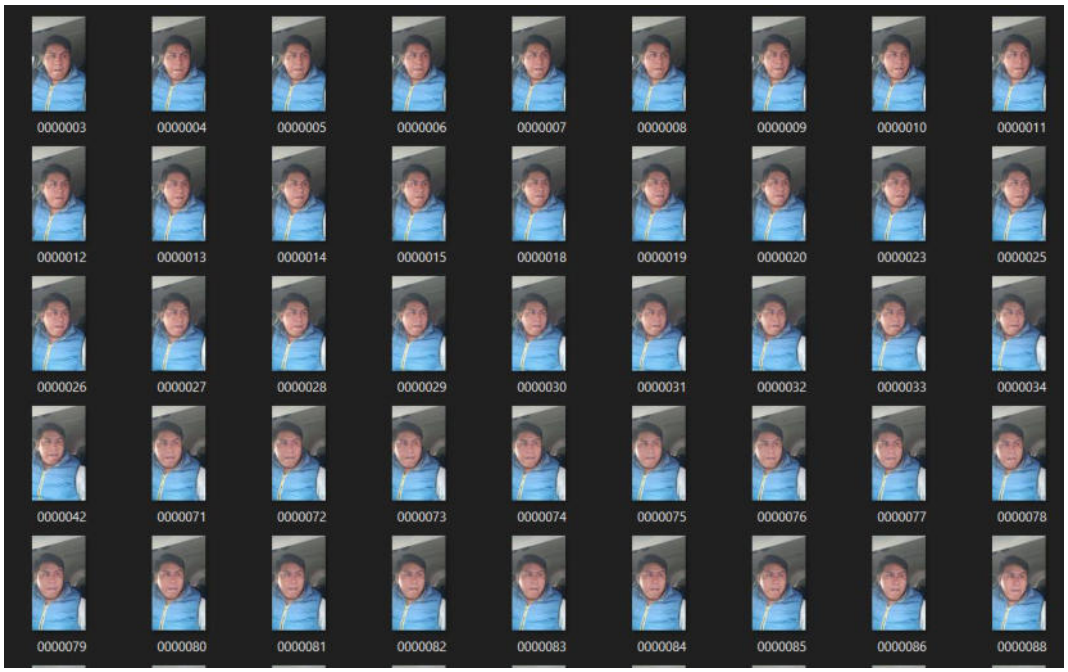
Ilustración 31
Resultados de las detecciones

Nombre del Video	Tiempo Derecha	Tiempo Izquierda	Tiempo Total	Minutos	% Distraccion	% Deteccion
P01V1	111.662	51.996	163.658	0:02:44	4.09	67.74
P01V2	264.314	231.696	496.01	0:08:16	12.40	94.95
P01V3	192.007	136.81	328.817	0:05:29	8.22	95.42
P02V1	71.306	67.371	138.677	0:02:19	3.47	78.89
P03V1	92.985	1505.074	1598.059	0:26:38	39.95	92.95
P04V1	119.2	2048.21	2167.41	0:36:07	54.19	92.90
P05V1	39.155	91.484	130.64	0:02:11	3.27	98.97
P07V1	19.144	144.948	164.092	0:02:44	4.10	98.94
P07V2	64.469	293.964	358.433	0:05:58	8.96	97.79
P08V1	66.27	144.381	210.651	0:03:31	5.27	93.52
P09V1	248.572	229.895	478.467	0:07:58	11.96	98.43
P10V1	128.839	156.087	284.926	0:04:45	7.12	99.48
P11V1	110.895	183.002	293.897	0:04:54	7.35	98.95
P12V1	164.959	37.121	202.079	0:03:22	5.05	89.53
P13V1	301.435	148.683	450.118	0:07:30	11.25	92.38
P14V1	84.447	291.229	375.676	0:06:16	9.39	97.42
P16V1	538.367	37.488	575.855	0:09:36	14.40	95.85
P17V1	107.06	136.243	243.303	0:04:03	6.08	74.87
P18V1	29.35	123.269	152.619	0:02:33	3.82	97.85
P19V1	112.229	155.253	267.483	0:04:27	6.69	93.73
P21V1	529.529	47.06	576.589	0:09:37	14.41	97.39
P22V1	159.756	183.603	343.358	0:05:43	8.58	96.67
P23V1	211.985	294.231	506.216	0:08:26	12.66	94.35
PROMEDIO	**163.82**	**293.00**	**456.83**	**00:07:37**	**11.42**	**93.00**

Fuente: Elaboración propia

El dataset construido a partir de videos de conductores en diferentes escenarios reales proporcionó una base de datos robusta para evaluar el desempeño del modelo. La validación de los datos y la clasificación de los videos permitieron segmentar correctamente los casos en los que el conductor mantenía la atención frente a la carretera y aquellos en los que se producían desviaciones de la mirada hacia los lados. Los resultados indican que el sistema tiene un nivel de precisión alto en la detección de distracciones, con una respuesta eficiente en tiempo real y una adecuada capacidad de integración con software de detección de somnolencia ya existente.

Ilustración 32
Dataset de imágenes de conductores



Fuente: Elaboración propia

4.2. Discusión

Los hallazgos obtenidos confirmaron que el seguimiento del iris mediante inteligencia artificial es una estrategia efectiva para mejorar la detección de distracciones en conductores interprovinciales. La implementación del modelo de MediaPipe y el análisis de puntos clave en la pupila demostraron ser técnicas viables para evaluar la dirección de la mirada con alta precisión. Además, la integración con software de detección de somnolencia amplía las funcionalidades del sistema, permitiendo una vigilancia más completa del estado de alerta del conductor.

Según Benites Cespedes (2024) sus resultados evaluaron la importancia de considerar las acciones que pueden afectar la capacidad de respuestas del conductor señalando la necesidad de aplicar estrategia y poder promover una conducción más segura, esta investigación afirma estos resultados según el análisis a nivel nacional identificado previamente.

Delgado Egas & Yandún Velasteguí (2022) destacó la realización de experimentos para verificar las señales a considerar ya sea síntomas de somnolencia o incluso enfermedades de los conductores, nuestras confirma este tipo de verificación permitiéndonos identificar estos síntomas y señales de una manera precisa.

Granda Zaruma & Valdivieso Delgado (2021) expresó el uso de inteligencia artificial para la prevención de accidentes de tránsito utilizándola para detectar los rasgos faciales y características de fatiga y somnolencia en conductores, al igual que nuestra investigación extrae el análisis de estos rasgos para y utilizar la inteligencia artificial para mejora la detección en la conducción en nuestro ámbito provincial.

Safarov et al. (2023) afirmó la mejora de esta detección con la posibilidad de combinar diferentes algoritmos, esta investigación afirme las zonas de mejora como la posición o iluminación del entorno en el que se trabaje.

Jebraeily et al. (2024) compartió la idea de combinar y mejorar los modelos en un enfoque de alta presión y buenas capacidades de detección, nuestra investigación muestras las diferentes áreas en las que puede mejorar la detección y comparte el ideal de modelos de mejor enfoque.

Jain et al. (2021) concluyó con la combinación de modelos para mejorar el rendimiento y la detección usando módulos EAR y eSpeak, nuestra investigación afirma estos resultados puesto que se analizaron las situaciones en las que el uso de diferentes modelos sería beneficioso para este tipo de detección.

V. Conclusiones

En esta tesis se halló mediante el seguimiento con iris con machine learning las distracciones en conductores interprovinciales, demostrando así la efectividad de esta metodología. El modelo de MediaPipe empleado demostró ser capaz de identificar con precisión la dirección de la mirada mediante el análisis de puntos clave en los ojos, permitiendo diferenciar entre una conducción atenta y una distracción lateral.

Se halló un nivel de precisión aceptable en el modelo de machine learning empleado para la detección de distracciones conductores interprovinciales, demostrando su eficiencia y desempeño ante esta investigación, es importante considerar futuras mejoras para optimizar su desempeño en escenarios con baja iluminación y reducir la interferencia de reflejos oculares. No obstante, los resultados obtenidos confirman que esta tecnología tiene un gran potencial para ser implementada en sistemas de asistencia a la conducción.

Se halló la capacidad de integración del modelo de machine learning en el sistema de monitoreo de somnolencia en conductores interprovinciales, incorporándose de manera efectiva sin comprometer su funcionalidad ni su rendimiento, así como la extracción de datos relevantes que nos permitieron construir un dataset a partir de los videos reales estableciendo una base sólida para la evaluación del sistema evidenciando su aplicabilidad en condiciones reales de conducción.

Se optimizó un modelo eficiente en términos de velocidad de procesamiento utilizando la solución FaceMesh de MediaPipe, la cual es menos robusta y está optimizada para el uso en dispositivos móviles, garantizando la detección en tiempo real de distracciones sin generar retrasos significativos en el análisis de datos.

VI. Recomendaciones

Con base en los resultados obtenidos, se presentan las siguientes recomendaciones para futuras investigaciones y aplicaciones del sistema desarrollado dirigido a investigadores en visión por computadora o inteligencia artificial, así como instituciones relacionadas con la seguridad vial y monitoreo vehicular:

Mejoras en el modelo de seguimiento del iris: dirigida a investigadores en visión por computadora o inteligencia artificial, se sugiere continuar con la optimización del algoritmo para mejorar su robustez ante variaciones de iluminación y minimizar interferencias causadas por reflejos oculares.

Ampliación del dataset: Para instituciones académicas y desarrolladores de sistemas de detección de somnolencia, la recolección de más videos en diferentes condiciones climáticas y de iluminación permitiría mejorar la generalización del modelo y su aplicabilidad en diversos contextos.

Integración con múltiples sensores: Para desarrolladores de tecnologías de seguridad vial y fabricantes de sistemas de monitoreo vehicular, complementar el seguimiento del iris con otras tecnologías, como detección de parpadeo o monitoreo del ritmo cardiaco, podría proporcionar un análisis más completo del estado del conductor.

Estas recomendaciones contribuirán a fortalecer la investigación y avanzar en el desarrollo de tecnologías más eficientes para la seguridad vial.

VII. Referencias

Agudelo, G., Aigneren, M., & Ruiz, J. (2008). *Diseños de investigación experimental y no-experimental*. https://revistas.udea.edu.co/index.php/ceo/article/view/6545/5996

Arias-Gómez, J., Ángel Villasís-Keever, M., & Guadalupe Miranda-Novales, M. (2016). *Metodología de la investigación*. www.nietoeditores.com.mx

Armando, D., & Flores, U. (2024). *Desarrollo y implementación en un sistema embebido de un sistema detector de la distracción en conductores mediante la estimación de la postura de la cabeza* [Universidad nacional de San Antonio abad del cusco facultad de ingeniería eléctrica, electrónica, informática y mecánica.]. https://repositorio.unsaac.edu.pe/handle/20.500.12918/10237

Bazarevsky, V., Kartynnik, Y., Vakunov, A., Raveendran, K., & Grundmann, M. (2019). *BlazeFace: Sub-millisecond Neural Face Detection on Mobile GPUs*. http://arxiv.org/abs/1907.05047

Benites Cespedes, G. (2024). *Desarrollo de un sistema de alerta de fatiga para conductores viales*. http://repositorio.iberopuebla.mx/licencia.pdf

Bulat, A., & Tzimiropoulos, G. (2017). *How far are we from solving the 2D & 3D Face Alignment problem? (and a dataset of 230,000 3D facial landmarks)*. https://doi.org/10.1109/ICCV.2017.116

Cano Lara, M., Rostro González, H., Salazar Hernández, M. C., & Camacho López, S. (2022). *Sistema de control para la prevención de accidentes en vehículos utilizando el reconocimiento de acciones faciales*. https://www.researchgate.net/publication/359471443

Caro, L. (2021). *7 Técnicas e Instrumentos para la Recolección de Datos*. http://biblioteca.udgvirtual.udg.mx/jspui/handle/123456789/2801

Danilo, I., & Santillán, G. (2008). *Visión Artificial y Procesamiento Digital de Imágenes usando Matlab*. Editorial no especificada.

https://elhacker.info/manuales/Lenguajes%20de%20Programacion/Matlab/vision%20artificial%20y%20procesamiento%20digital%20de%20imagenes%20matlab-Ibarra.pdf

Delgado Egas, K. D., & Yandún Velasteguí, M. A. (2022). Sistema de detección de somnolencia para conductores de taxis en la ciudad de Tulcán. *Horizontes de Enfermería*, *12*, 52–67. https://doi.org/10.32645/13906984.1171

Denman, C. A., & Haro, A. (2002). *Antología de métodos cualitativos en la investigación social* (Vol. 14). Colegio de Sonora. https://www.scielo.org.mx/pdf/regsoc/v14n23/v14n23a14.pdf

Dias Ramires, J. (2021). *Aprendizaje Automático y Aprendizaje Profundo*. https://www.scielo.cl/pdf/ingeniare/v29n2/0718-3305-ingeniare-29-02-180.pdf

Díaz-Chang, T., & Arredondo, E.-H. (2022). La técnica de seguimiento ocular y el estudio de modelos tácitos mediante criterios subjetivos y conductuales. *Innovaciones Educativas*, *24*(36), 37–55. https://doi.org/10.22458/ie.v24i36.3894

Flores-Monroy, J., Nakano-Miyatake, M., Escamilla-Hernández, E., & Pérez-Meana, H. (2023). Detección de somnolencia y distracción en conductores y su implementación en dispositivos móviles. *Información Tecnológica*, *34*(4), 1–12. https://doi.org/10.4067/s0718-07642023000400001

Géron, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow : concepts, tools, and techniques to build intelligent systems* (Second Edition). O'Reilly Media, Inc.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning.* MIT Press. https://doi.org/10.1007/s10710-017-9314-z

Granda Zaruma, F. A., & Valdivieso Delgado, D. S. (2021). *Sistema de detección de somnolencia a través de visión asistida por computadora en el periodo abril*. Instituto Tecnologico Sudamericano.

Hernández Sampieri, Roberto., & Mendoza Torres, C. Paulina. (2018). *Metodología de la investigación : las rutas cuantitativa, cualitativa y mixta*. McGraw-Hill Education.

Huamán Olarte, R. J., & Mujica Alban, E. (2020). Factors associated to sleep quality on informal drivers of interprovincial buses at high geographic altitude in Peru. *Anales de La Facultad de Medicina*, *81*(2). https://doi.org/10.15381/anales.v81i2.18105

Jain, M., Bhagerathi, B., & C N, Dr. S. (2021). Real-Time Driver Drowsiness Detection using Computer Vision. *International Journal of Engineering and Advanced Technology*, *11*(1), 109–113. https://doi.org/10.35940/ijeat.A3159.1011121

Jebraeily, Y., Sharafi, Y., & Teshnehlab, M. (2024). Driver Drowsiness Detection Based on Convolutional Neural Network Architecture Optimization Using Genetic Algorithm. *IEEE Access*, *12*, 45709–45726. https://doi.org/10.1109/ACCESS.2024.3381999

Kartynnik, Y., Ablavatski, A., Grishchenko, I., & Grundmann, M. (2019). *Real-time Facial Surface Geometry from Monocular Video on Mobile GPUs*. http://arxiv.org/abs/1907.06724

Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. In *Nature* (Vol. 521, Issue 7553, pp. 436–444). Nature Publishing Group. https://doi.org/10.1038/nature14539

Lozada, J. (2014). *Investigación Aplicada: Definición, Propiedad Intelectual e Industria*. https://dialnet.unirioja.es/descarga/articulo/6163749.pdf

Lugaresi, C., Tang, J., Nash, H., McClanahan, C., Uboweja, E., Hays, M., Zhang, F., Chang, C.-L., Yong, M. G., Lee, J., Chang, W.-T., Hua, W., Georg, M., & Grundmann, M. (2019). *MediaPipe: A Framework for Building Perception Pipelines*. http://arxiv.org/abs/1906.08172

Martínez Rodríguez, A. L., & Maldonado Rivera, J. L. (2024). Tras bastidores del ojo humano: anatomía, problemas comunes y soluciones. *Revista Digital Universitaria*, *25*(2). https://doi.org/10.22201/cuaieed.16076079e.2024.25.2.1

Mauricio, J. A. (2013). *Análisis de Series Temporales series temporales página ll observaciones preliminares*. https://www.ucm.es/data/cont/docs/518-2013-11-11-JAM-IAST-Libro.pdf

Mayon, E., & Limaquispe, R. (2018). *Sistema de detección de somnolencia mediante inteligencia artificial en conductores de vehículos para alertar la ocurrencia de accidentes de transito*. https://repositorio.unh.edu.pe/items/df355d84-7c76-40cf-bdc2-5e17bb75ebc2

Ministerio de transportes y comunicaciones. (2017). *Plan estratégico nacional ministerio de transportes y comunicaciones secretaría técnica fase de análisis prospectivo*. https://www.mtc.gob.pe/cnsv/documentos/PENsv_2017-2021.pdf

Ministerio de transportes y comunicaciones. (2023). *"Política Nacional Multisectorial de Seguridad Vial."* https://cdn.www.gob.pe/uploads/document/file/4898855/Pol%C3%ADtica%20Nacional%20Multisectorial%20de%20Seguridad%20Vial%202023%20%E2%80%93%202030.pdf?v=1690229851

Montgomery, D. C., & Wiley, J. (2010). *Introduction to Statistical Quality Control* (Fifth). Don Fowley. https://www.uaar.edu.pk/fs/books/12.pdf

Morales Gonzales, R. A., Guzmán Valdivia, J. A., & Herrera Quispe, J. A. (2024). Software de inteligencia artificial para detectar microsueños en conductores. *Campus*, *29*(38), 311–336. https://doi.org/10.24265/campus.2024.v29n38.05

Paxi Apaza, W. J. (2023). *Predicción De Series De Tiempo De Radiación Solar En El Sur Del Perú Aplicando Deep Learning, Caso: Moquegua Y Tacna.* [Tesis, Universidad Nacional de Moquegua]. https://hdl.handle.net/20.500.14655/504

Pérez Barreto, L. (2011). *Diagnóstico y tratamiento de un estrabismo*. https://dialnet.unirioja.es/descarga/articulo/3717519.pdf

Ponce Gallegos, J. C., Torres Soto, A., Quezada Aguilera, F. S., Silva Sprock, A., & Martinez Flor, E. U. (2014). *Inteligencia Artificial.* (First Edition). Iniciativa Latinoamericana de Libros de Texto Abiertos. http://www.proyectolatin.org/

Rouhiainen, L. (2018). *Inteligencia artificial 101 cosas que debes saber hoy sobre nuestro futuro inteligencia artificial*. https://proassetspdlcom.cdnstatics2.com/usuaris/libros_contenido/arxius/40/39307_Inteligencia_artificial.pdf

Rupay, M. A. (2018). *Luchando contra la informalidad en el transporte terrestre de personas: el caso de coordinación de la sede desconcentrada Junín de la Superintendencia de Transporte Terrestre, Carga y Mercancías* [Pontificia Universidad Católica Del Perú]. http://hdl.handle.net/20.500.12404/13755

Safarov, F., Akhmedov, F., Abdusalomov, A. B., Nasimov, R., & Cho, Y. I. (2023). Real-Time Deep Learning-Based Drowsiness Detection: Leveraging Computer-Vision and Eye-Blink Analyses for Enhanced Road Safety. *Sensors*, *23*(14). https://doi.org/10.3390/s23146459

Salazar Olarte, C. A. (2021). pupilometría y el eye tracking como herramientas del neuromarketing. *Vivat Academia*, 227–243. https://doi.org/10.15178/va.2021.154.e1345

Sanchis Reig, A., & Pujol Lopez, F. A. (2022). *Interfaz hombre-máquina mediante estimación de pose*. http://hdl.handle.net/10045/124652

Super intendencia de transporte terrestre de personas, carga y mercancias. (2022). Reporte Estadístico de Siniestros Viales 2022. *Ministerio de Transportes y Comunicaciones*. https://cdn.www.gob.pe/uploads/document/file/4489498/Reporte%20Estad%C3%ADstico%20de%20Siniestros%20Viales%202022.pdf

Vakunov, A., & Lagun, D. (2020, August 6). *MediaPipe Iris: Real-time Iris Tracking & Depth Estimation*. Https://Research.Google/Blog/Mediapipe-Iris-Real-Time-Iris-Tracking-Depth-Estimation/.

Vazquez Martinez, M. G. (2017). *Muestreo probabilístico y no probabilístico*. https://www.gestiopolis.com/wp-content/uploads/2017/02/muestreo-probabilistico-no-probabilistico-guadalupe.pdf

Villán, A. F., Fernández, R. U., & Tejedor, R. C. (2017). Sistema Automático Para la Detección de Distracción y Somnolencia en Conductores por Medio de Características Visuales Robustas. *RIAI - Revista Iberoamericana de Automatica e Informatica Industrial*, *14*(3), 307–328. https://doi.org/10.1016/j.riai.2017.05.001

Viola, P., & Jones, M. (2001). *Rapid Object Detection using a Boosted Cascade of Simple Features*. https://doi.org/https://ieeexplore.ieee.org/document/990517

World health organization. (2023). *Global status report on road safety 2023*. https://www.who.int/teams/social-determinants-of-health/safety-and-mobility/global-status-report-on-road-safety-2023

Yan, G., & Ivan Grishchenko, G. (2022). *Model card mediapipe facemesh*. https://storage.googleapis.com/mediapipe-assets/Model%20Card%20MediaPipe%20Face%20Mesh%20V2.pdf

Yang, E., & Yi, O. (2024). Enhancing Road Safety: Deep Learning-Based Intelligent Driver Drowsiness Detection for Advanced Driver-Assistance Systems. *Electronics (Switzerland)*, *13*(4). https://doi.org/10.3390/electronics13040708

Zhang, Z., Luo, P., Loy, C. C., & Tang, X. (2014). *Facial Landmark Detection by Deep Multi-task Learning*. https://link.springer.com/chapter/10.1007/978-3-319-10599-4_7

VIII. Anexo

ANEXO 1: Matriz de consistencia

Seguimiento del iris con Machine Learning para la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, Moquegua, 2024

<table>
<tr><th>Problema general</th><th>Objetivo general</th><th>Variables independiente</th><th>Dimensiones</th><th>Tipo de investigación</th><th>Población</th></tr>
<tr><td>¿Cómo se halla, mediante el seguimiento del iris con machine learning, la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, en Moquegua 2024?</td><td>Hallar mediante el seguimiento del iris con machine learning la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, en Moquegua 2024.</td><td>Seguimiento del Iris con Machine Learning</td><td>- Precisión del Modelo de Machine Learning
- Capacidad de Integración
- Tiempo de Procesamiento</td><td>Aplicativo</td><td>31 Conductores interprovinciales</td></tr>
<tr><th>Primer problema específico</th><th>Primer objetivo especifico</th><th>Variables dependiente</th><th>Dimensiones</th><th>Nivel de investigación</th><th>Muestra</th></tr>
<tr><td>¿Qué nivel asegura la precisión del modelo de machine learning para la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, en Moquegua 2024?</td><td>Hallar el nivel que asegure la precisión del modelo de machine learning para la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, en Moquegua 2024.</td><td rowspan="6">Detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales</td><td rowspan="6">- Tasa de Detección de Distracciones
- Compatibilidad en Entornos Reales</td><td>Exploratoria</td><td rowspan="6">Se usarán 31 videos del trayecto de viaje interprovincial de los conductores</td></tr>
<tr><th>Segundo problema específico</th><th>Segundo objetivo especifico</th><th>Diseño de investigación</th></tr>
<tr><td>¿Qué capacidad de integración tiene el sistema para la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, en Moquegua 2024?</td><td>Hallar la capacidad de integración que tiene el sistema para la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, en Moquegua 2024.</td><td rowspan="3">Estudio cuasi experimental</td></tr>
<tr><th>Tercer problema específico</th><th>Tercer objetivo especifico</th></tr>
<tr><td>¿Cómo optimizar el tiempo de procesamiento del sistema para la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, en Moquegua 2024?</td><td>Optimizar el tiempo de procesamiento del sistema para la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, en Moquegua 2024.</td></tr>
</table>

"UNIVERSIDAD NACIONAL DE MOQUEGUA"

VICERRECTORADO DE INVESTIGACIÓN

FORMATO DE AUTORIZACIÓN DE PUBLICACIÓN EN EL REPOSITORIO INSTITUCIONAL UNAM

Formulario de autorización para la publicación electrónica en la página web del Repositorio Institucional de la Universidad Nacional de Moquegua, de conformidad con la Ley N° 30035 Ley que regula el Repositorio Nacional Digital de Ciencia, Tecnología e Innovación de Acceso Abierto y Resolución de Comisión Organizadora N° 041-2022-UNAM que aprueba el Reglamento que regula el Repositorio Institucional Digital de la UNAM.

1. DATOS DEL AUTOR

Nombres y Apellidos : Oscar Ali Huaco Limache
DNI/Carnet de Extranjería/Pasaporte N° : 72360426
Correo electrónico : oscarhuacolimache@gmail.com
Teléfono/Celular : 927990681

2. GRADO, TITULO O ESPECIALIZACIÓN (Marque con una X)

Bachiller	Título Profesional	Magister	Doctor	Segunda Especialidad
	X			

3. TIPO DE PUBLICACIÓN (Marque con una X)

a) Articulo ( )
b) Tesis de pregrado (X)
c) Tesis de Maestría ( )
d) Tesis de Doctorado ( )
e) Monografía ( )
f) Reporte de caso científico o hallazgos ( )
g) Libro ( )
h) Parte de un libro ( )
i) Revisión ( )
j) Conferencia ( )
k) Presentación ( )
l) Artículo preliminar ( )
m) Articulo antes de ser publicado ( )
n) Artículo de prensa ( )
o) Documentos internos ( )
p) Imagen ( )
q) Documentos técnicos ( )
r) Ponencias presentadas en eventos científicos (Jornada, Congreso, Simposio Conferencias, etc.) ( )
s) Informes de suficiencia profesional ( )
t) Patentes producidas por académicos/as ( )

4. TIPO DE TRABAJO DE INVESTIGACIÓN (Marque con una X)

a) Tesis (X)
b) Trabajo de Investigación ( )
c) Trabajo de suficiencia profesional ( )
d) Trabajo académico ( )

5. DATOS DE LA PUBLICACION

a) Título : Seguimiento del iris con machine learning para la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, Moquegua, 2024
b) Campo del conocimiento OCDE (Indicar el código de clasificación OCDE de la obra : https://catalogos.concytec.gob.pe/vocabulario/ocde_ford.html) : .....
c) Fecha de publicación : .....

6. DATOS DEL ASESOR:

a) Nombres y Apellidos : José Antonio Guzmán Valdivia
b) DNI/Pasaporte/Cédula : 40717092
c) ORCID : 0000-0002-4184-3421

FIRMA : .....

DOCUMENTO DE IDENTIDAD : 72360426
NOMBRES Y APELLIDOS : Oscar Ali Huaco Limache

"UNIVERSIDAD NACIONAL DE MOQUEGUA"

VICERRECTORADO DE INVESTIGACIÓN

LICENCIAS

Licencia Estándar

Bajo los siguientes términos, autorizo el depósito de mi trabajo de investigación en el Repositorio Institucional Digital de la UNAM.

Con la autorización de depósito da mi trabajo de investigación, otorgo a la Universidad Nacional de Moquegua, una Licencia No Exclusiva para reproducir. distribuir, comunicar al público, transformar (únicamente mediante su traducción a otros idiomas) y poner a disposición del público mi trabajo de investigación (incluido el resumen), en formato físico o digital, en cualquier medio, conocido o por conocerse, a través de los diversos servicios provistos por la Universidad, creados o por crearse, tales como el Repositorio Institucional Digital de la UNAM, Colección de Tesis, entre otros, en el Perú y en el extranjero, por el tiempo y veces que considere necesarias, y libre de remuneraciones.

En virtud de dicha Licencia, la UNIVERSIDAD NACIONAL DE MOQUEGUA, podrá reproducir mi trabajo de investigación en cualquier tipo de soporte y en más de un ejemplar, sin modificar su contenido, solo con los propósitos de seguridad, respaldo y preservación.

Declaro que el trabajo de investigación es una creación de mi autoría y exclusiva titularidad, o coautoría con titularidad compartida, y me encuentro facultado a conceder la presente licencia y, asimismo, garantizo que dicho trabajo de investigación no infringe derechos de autor de terceras personas.

La UNIVERSIDAD NACIONAL DE MOQUEGUA consignara el nombre del/los autor/es del trabajo de investigación, y no le hará ninguna modificación más de la permitida en la presente licencia.

Autorizo el depósito (marque con una X).

(X) **SI autorizo que se deposite inmediatamente.**

FIRMA : .....

DOCUMENTO DE IDENTIDAD : 72360426

NOMBRES Y APELLIDOS : Oscar Ali Huaco Limache

FECHA : 12 de mayo 2025



ANEXO VIII

DECLARACIÓN JURADA DE ORIGINALIDAD DE TRABAJO DE INVESTIGACIÓN / TESIS / TRABAJO DE SUFICIENCIA PROFESIONAL

Yo, Oscar Ali Huaco Limache ,
bachiller de la Escuela Profesional de:
Ingeniería de Sistemas e Informática ,
de la Universidad Nacional de Moquegua, identificado(a) con DNI Nº... 72360426 , autor(a) del Trabajo de Investigación / Tesis / Trabajo de suficiencia profesional denominado:
Seguimiento del iris con machine learning para la detección de distracciones en el sistema de monitoreo de somnolencia en conductores interprovinciales, Moquegua, 2024

Declaro bajo juramento que:

1. El trabajo de investigación es auténtico, siendo resultado de mi trabajo personal, que no se ha copiado, que no se ha utilizado ideas, formulaciones, citas integrales e ilustraciones diversas, sacadas de cualquier tesis, obra, artículo, memoria, etc., (en versión digital o impresa), sin mencionar de forma clara y exacta su origen o autor, tanto en el cuerpo del texto, figuras, cuadros, tablas u otros que tengan derechos de autor. Por tanto, el trabajo de investigación no ha sido plagiado total ni parcialmente.
2. El trabajo de investigación no ha sido autoplagiada, es decir, no ha sido publicada ni presentada anteriormente para obtener algún grado académico previo o título profesional.
3. Los datos presentados en los resultados son reales, no han sido falseados, ni duplicados, ni copiados y por tanto los resultados que se presentan en el trabajo de investigación constituirán aporte a la realidad investigada.

Soy consciente de que, el hecho de no respetar los derechos de autor y hacer plagio, es objeto de sanciones universitarias y/o legales, por lo que asumo cualquier responsabilidad que pudiera derivarse de irregularidades en el trabajo de investigación, así como de los derechos sobre la obra presentada.

Moquegua, 12 mayo 2025



Huella digital

Nombres y Apellidos: Oscar Ali Huaco Limache
DNI: 72360426

Oscar Huaco Limache

TESIS.pdf

REVISION DE INFORME

Revision de Informe Final de Tesis

Universidad Nacional de Moquegua

Detalles del documento

Identificador de la entrega
trn:oid:::1:3178424009

Fecha de entrega
9 mar 2025, 11:15 p.m. GMT-5

Fecha de descarga
9 mar 2025, 11:24 p.m. GMT-5

Nombre de archivo
TESIS.pdf

Tamaño de archivo
1.2 MB

51 Páginas

10,152 Palabras

57,974 Caracteres

16% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- Bibliografía

Fuentes principales

14% Fuentes de Internet
3% Publicaciones
8% Trabajos entregados (trabajos del estudiante)

turnitin Página 2 of 60 - Descripción general de integridad Identificador de la entrega trn:oid:::1:3178424009

RESOLUCIÓN DE CONSEJO UNIVERSITARIO

N° 390-2025-CU-UNAM

Moquegua, 05 de junio de 2025

VISTOS:

El Proveído N° 2080-2025 de fecha 30 de mayo de 2025 emitido por el Rectorado, el Informe N° 220-2025-UNAM-R/SG de fecha 30 de mayo de 2025, el Informe Técnico N° 063-2025-UNAM/SEGE/GYT de fecha 30 de mayo de 2025 emitidos por el Secretario General de la UNAM, el Acuerdo del Pleno del Consejo Universitario de Sesión Ordinaria N° 05-2025-SO-CU-UNAM, de fecha 04 de junio de 2025, y;

CONSIDERANDO:

Que, conforme al 4to párrafo del artículo 18, de la Constitución Política del Perú, dispone que cada Universidad es autónoma en su régimen normativo, de gobierno, académico, administrativo y económico. Y el artículo 8° de la Ley Nº 30220-Ley Universitaria, establece que la referida autonomía inherente a las Universidades, se ejerce de conformidad con la Constitución y demás normativa aplicable. Concordante con el artículo 1, de la Ley Nº 31520, Ley que restablece la autonomía y la institucionalidad de las universidades peruanas, así como la Ley N° 32141, Ley que modifica la Ley N° 30220-Ley Universitaria, a fin de fortalecer la institucionalidad de las Universidades Públicas licenciadas;

Que, el Artículo 58, de la Ley N° 30220-Ley Universitaria, establece que el Consejo Universitario es el máximo órgano de gestión, dirección y ejecución académica y administrativa de la Universidad. Concordante con el artículo 14° del Estatuto de la UNAM, aprobado bajo Resolución N° 578-2021-UNAM;

Que, el artículo 59 de la Ley Universitaria-Ley N° 30220, establece las atribuciones del Consejo Universitario, y específicamente el numeral 59.9, establece; Conferir los grados académicos y los títulos profesionales aprobados por las Facultades y Escuela de Posgrado, así como otorgar distinciones honoríficas y reconocer y revalidar los estudios, grados y títulos de universidades extranjeras, cuando la universidad está autorizada por la Superintendencia Nacional de Educación Superior Universitaria. Concordante con el numeral 9, del artículo 16 del Estatuto de la UNAM;

Que, el Sr. Rector es el personero y representante legal de la Universidad Nacional de Moquegua, conforme a lo dispuesto por la Ley Nº 30220-Ley Universitaria, tiene a su cargo la Dirección, Conducción y Gestión del Gobierno Universitario en todos sus ámbitos, concordante con el artículo 18 y numeral 2 del artículo 20° del Estatuto de la UNAM;

Que, mediante Informe Técnico N° 063-2025-UNAM/SEGE/GYT e Informe N° 220-2025-UNAM-R/SG de fecha 30 de mayo de 2025, el Secretario General de la UNAM, remite al Rectorado dos (02) expedientes para el trámite de título profesional de Ingeniero de Sistemas e Informática de los bachilleres: HUACO LIMACHE, OSCAR ALI y LARIJO LLANOS, ERIKA YANETH de la Escuela Profesional de Ingeniería de Sistemas e Informática, quienes se encuentran aptos para la expedición del título profesional de Ingeniero de Sistemas e Informática, al haber cumplido satisfactoriamente con los requisitos legales y reglamentarios, exigidos en el Reglamento de Grados y Títulos de la Universidad Nacional de Moquegua, conforme lo señala la Dirección de Actividades y Servicios Académicos y la Dirección de la Escuela Profesional de Ingeniería de Sistemas e Informática; razón por la cual, el señor Secretario General incluye dicho expediente como punto de agenda para ser tratado en Sesión Ordinaria de Consejo Universitario de fecha 04 de junio de 2025;

Que, el artículo 44° de la Ley N° 30220, Ley Universitaria señala que las universidades otorgan los grados académicos de Bachiller, Maestro, Doctor y los Títulos Profesionales que correspondan, a nombre de la Nación (...). Asimismo, la Ley N° 31803, modifica el artículo en mención adicionando; La Superintendencia Nacional de Educación Superior Universitaria (SUNEDU) determina los criterios, así como establece y supervisa el procedimiento administrativo para el reconocimiento de grados y títulos otorgados en el extranjero, en el marco de la normativa vigente;

Que, el numeral 45.2 del artículo 45° de la Ley Nº 30220, Ley Universitaria, precisa los requisitos mínimos para la obtención del título profesional, como son: el grado de Bachiller y la aprobación de una tesis o trabajo de suficiencia profesional. Asimismo, establece que el título profesional solo se puede obtener en la universidad en la cual se haya obtenido el grado de bachiller;

Que, mediante Resolución de Comisión Organizadora N° 1153-2021-UNAM, se aprobó el Reglamento de Grados y Títulos de la Universidad Nacional de Moquegua, el mismo que fue modificado a través de las Resoluciones de Comisión Organizadora N° 410; 453 y 890-2022, N° 880-2023-UNAM y N° 081, 484-2024-UNAM el cual establece los requisitos y norma los procedimientos para la obtención de los grados académicos y títulos profesionales conferidos por esta Casa Superior de Estudios;

Que, bajo el amparo de los considerandos precedentes, el Pleno del Consejo Universitario en Sesión Ordinaria N° 05-2025-SO-CU-UNAM, de fecha 04 de junio de 2025, emitió, el siguiente, Acuerdo; POR UNANIMIDAD: CONFERIR, a nombre de la Nación el título profesional de Ingeniero de Sistemas e Informática por la modalidad de sustentación de tesis a los bachilleres: HUACO LIMACHE, OSCAR ALI y LARIJO LLANOS, ERIKA YANETH de la Escuela Profesional de Ingeniería de Sistemas e Informática, de la Facultad de Ingeniería y Arquitectura de la Universidad Nacional de Moquegua;

En uso de las facultades y atribuciones conferidas por el Art. 18, de la Constitución Política del Perú, la Ley N° 30220-Ley Universitaria, el Estatuto de la UNAM, y a lo acordado por el pleno del Consejo Universitario;

Domicilio Fiscal: Prolongación Av., Ancash S/N - Moquegua
RUC: 20449347448 - Teléfono: (053) 670168
Página Web: www.unam.edu.pe

RESOLUCIÓN DE CONSEJO UNIVERSITARIO
N° 390-2025-CU-UNAM

Moquegua, 05 de junio de 2025

SE RESUELVE:

ARTÍCULO 1°: CONFERIR, A NOMBRE DE LA NACIÓN a los bachilleres

- **OSCAR ALI HUACO LIMACHE**
  TESIS : "SEGUIMIENTO DEL IRIS CON MACHINE LEARNING PARA LA DETECCIÓN DE DISTRACCIONES EN EL SISTEMA DE MONITOREO DE SOMNOLENCIA EN CONDUCTORES INTERPROVINCIALES, MOQUEGUA 2024" cuyo Asesor fue el Mgr. José Antonio Guzmán Valdivia

- **ERIKA YANETH LARIJO LLANOS**
  TESIS : "COMPARACIÓN DE MODELOS PREDICTIVOS BASADOS EN TÉCNICAS DE MACHINE LEARNING PARA LA CLASIFICACIÓN DE RENDIMIENTO ACADÉMICO DE ESTUDIANTES DE LA UNIVERSIDAD NACIONAL DE MOQUEGUA, EN EL CONTEXTO DEL COVID-19, 2021" cuyo Asesor fue la Dra. Vaneza Flores Gutiérrez

El **TÍTULO PROFESIONAL DE INGENIERO DE SISTEMAS E INFORMÁTICA**
Por la modalidad de SUSTENTACIÓN DE TESIS, de la Escuela Profesional de Ingeniería de Sistemas e Informática de la Facultad de Ingeniería y Arquitectura de la Universidad Nacional de Moquegua.

ARTÍCULO 2°: ENCARGAR, al Secretario General a través de quien corresponda, para que realice las acciones pertinentes relacionadas con la inscripción correspondiente en el Registro de Grados y Títulos de la Superintendencia Nacional de Educación Superior Universitaria – SUNEDU.

ARTÍCULO 3°: DISPONER el cumplimiento de la presente Resolución a todas las dependencias de la Universidad Nacional de Moquegua.

ARTÍCULO 4°: DISPONER la publicación de la presente resolución en el Portal Institucional de la Universidad Nacional de Moquegua www.unam.edu.pe

REGÍSTRESE, PUBLÍQUESE, Y CÚMPLASE;

UNIVERSIDAD NACIONAL DE MOQUEGUA UNAM SECRETARÍA GENERAL

ABOG. EDGAR PINTO HUANCAVILCA
SECRETARIO GENERAL

UNIVERSIDAD NACIONAL DE MOQUEGUA UNAM CONSEJO UNIVERSITARIO

DR. HUGO RUBEN MARCA MAQUERA
RECTOR
PRESIDENTE DEL CONSEJO UNIVERSITARIO

DISTRIBUCION:
VRA
VRI
DAJ
FACIA
FACSAD
FACISA
OPP
DIGA
OTI
c.c. Arch.