

Reporte Final (100 %) del Periodo Sabático

No. de autorización AS-1-135/2024

Estudio y aplicación de técnicas de Inteligencia Artificial para la asistencia de conducción en vehículos autónomos

A.1 Proyecto de Investigación Científica

Dr. Dante Mújica Vargas

2025

9

Dante
9/01/25

1. Identificación del Proyecto

Instituto o Centro:

Sección de estudios de Posgrado e Investigación (SEPI) del Instituto Politécnico Nacional

Nombre del/de la docente:

Dr. Dante Mújica Vargas

Título del proyecto:

Estudio y aplicación de técnicas de Inteligencia Artificial para la asistencia de conducción en vehículos autónomos

Tipo de investigación:

A.1 Proyecto de Investigación Científica

Duración del proyecto:

12 meses

Fecha de inicio del proyecto:

01 de febrero de 2024

Fecha de término del proyecto:

31 de enero de 2025

Índice general

1. Identificación del Proyecto	2
2. Resultados	3
2.1. Resumen del proyecto	3
2.1.1. Introducción	3
2.1.2. Objetivos	4
2.1.3. Metas	5
2.1.4. Desarrollo y resultados del proyecto	5
2.1.5. Conclusiones/Observaciones	8
2.2. Objetivo del proyecto	8
2.3. Metas	8
2.4. Metodología	9
2.5. Difusión	11
2.6. Beneficios y Problemas	11
2.7. Información adicional	12
Referencias	13
Anexos	20
A. Actividades desarrolladas	21
B. Tesis de maestría en desarrollo	63
C. Tesis de maestría finalizadas	68
D. Artículos científicos en revistas indizadas enviados	69
E. Memorias en extenso en congresos	77
F. Actividades Instituto Politécnico Nacional	83

Handwritten signatures and marks in blue ink at the bottom right of the page.

2. Resultados

2.1. Resumen del proyecto

2.1.1. Introducción

Una de las razones del aumento de accidentes de tráfico se debe a la falta de atención del conductor al camino y a diversos obstáculos ignorados que pueden presentarse a simple vista o en puntos ciegos durante el desplazamiento longitudinal y lateral, es decir durante la conservación y el cambio de carril. La inatención al camino puede ser generada por varios factores, tales como el estado de somnolencia del conductor y el enfoque de atención del conductor en otras actividades, esta inatención con frecuencia conlleva a situaciones de riesgo que abarcan desde una pérdida material hasta accidentes mortales. Con el objetivo de tratar de minimizar el error humano, la Sociedad de Ingenieros Automotrices (SAE) sugiere que en la actividad de conducción autónoma se implementan sistemas para asistencia que brindan alertas y/o recomendaciones con base a la detección de obstáculos en el entorno, conservación y cambio de carriles, así como el monitoreo del conductor en tiempo real, de tal forma que se detecten y alerten posibles situaciones de riesgo que representen un peligro para el conductor y los pasajeros del vehículo.

Este trabajo de investigación tiene por objeto desarrollar un par de asistentes de conducción. El primero de ellos permitirá monitorear el estado de atención del conductor; de manera específica, detectar de la postura de la cabeza (hacia arriba, abajo, derecha o izquierda), estimar la mirada (hacia arriba, abajo, derecha, izquierda o está observado hacia adelante) y detectar de fatiga (está bostezando o parpadeando). Mientras que el segundo, estará enfocado en el trazado y selección de trayectorias para un vehículo autónomo, en las tareas de conservación y/o cambio de carril. De manera preliminar la metodología se que sugiere para el primer asistente, requiere la detección de la postura de la cabeza, la estimación de la mirada y la detección de la fatiga, estas tres tareas se deben realizar mediante técnicas de visión por computadora. se sugiere la utilización de redes neuronales basadas en Aprendizaje Profundo, mientras que el reconocimiento del estado de concentración se pretende utilizar un controlador difuso. Mientras que para el segundo asistente, se contempla utilizar el espacio de Frenet para generar las trayectorias mediante algoritmos polinomiales, y hacer la selección de la trayectoria que se apegue a las condiciones mediante un método de toma de decisiones con múltiples criterios basado en la teoría difusa.

Al finalizar este trabajo de investigación se espera haber desarrollado dos sistemas computacionales que puedan ser utilizados como asistentes de conducción para las tareas específicas descritas previamente.

2.1.2. Objetivos

El objetivo general del proyecto es examinar y evaluar técnicas de Inteligencia Artificial para desarrollar asistentes de conducción para monitorear el estado de conducción, así como para planificación y selección de trayectorias, con el fin de prevenir accidentes vehiculares.

En el primer semestre del proyecto se desarrollaron un asistente para monitorear el estado de conducción basado en aprendizaje profundo y fusión de índices, así como una variante en la cual se reemplazó la técnica heurística de la fusión de índices por una técnica más robusta como es la inferencia difusa. En el segundo semestre del proyecto se desarrolló un asistente para la generación y selección de trayectorias durante el desplazamiento vehicular, para ello se consideró el espacio de Frenet para la generación de trayectorias, como una mejor alternativa al espacio cartesiano para describir mejor la geometría de las carreteras. Posteriormente, se consideró la Técnica para Orden de Preferencia por Semejanza a la Solución Ideal (TOPSIS) en su variante difusa, para seleccionar la trayectoria con menos riesgo a sufrir colisiones.

Objetivos Específicos Se cumplió el alcance programado de todos los objetivos específicos de este proyecto de investigación. Se resaltan en color azul, los objetivos atendidos en el segundo periodo.

- Investigar en el estado del arte y literatura modelos basados en Aprendizaje Profundo, para detectar de la postura de la cabeza, estimar la mirada y detectar de fatiga del conductor.
- Poner a prueba los modelos seleccionados y estimar su rendimiento.
- Investigar en el estado del arte y literatura sobre el diseño sistemas de inferencia difusa basados en reglas.
- Desarrollar y evaluar el rendimiento del sistema de inferencia difusa para estimar el estado de conducción.
- Analizar los conceptos matemáticos relacionados con el sistema de Frenet, y su contexto en la generación de trayectorias para vehículos autónomos.
- Investigar el estado del arte y la literatura sobre métodos de toma de decisiones, que pueda ser utilizada en el contexto del desplazamiento vehicular, haciendo énfasis en TOPSIS.
- Desarrollar y evaluar un método para selección de trayectorias.
- Elaborar documentación con los resultados obtenidos, y publicar en congresos o revistas indicadas.

Una descripción detallada del desarrollo de estos objetivos se presenta en el Anexo A

2.1.3. Metas

De acuerdo al programa de trabajo, se atendió en su totalidad el compromiso establecido en las siguientes metas:

Dos tesis de maestría en desarrollo Se están dirigiendo a nivel maestría los trabajos de investigación titulados *Análisis de algoritmos de visión por computadora para un asistente de mantenimiento de carril* y *Recepción de iluminación para conducción autónoma en escenas nocturnas*.

Una tesis de maestría concluida La tesis *Implementación de estrategias avanzadas utilizando TOPSIS para la selección óptima de trayectoria de vehículos autoconducidos* fue concluida, lo que permitió la titulación con mención honorífica del estudiante.

Dos artículos científicos en revistas indizadas enviados El artículo *A hybrid deep learning-fuzzy inference scheme for driving supervision* se sometió a la revista *Intelligenza Artificiale* indizada en JCR. Mientras que el artículo *A TOPSIS-based multi-attribute decision-making approach for trajectory selection within an obstacle-rich environment* fue sometido en la revista *Applied Soft Computing* indizada en JCR.

Dos memorias en extenso de congreso Los artículos *Deep learning and index fusion-based driving monitoring system* y *Fine-Tuning the TOPSIS Technique and Transferring Knowledge of Different Driving Styles* fueron presentados en el congreso *Conferences and Workshops in Telematics and Computing WITCOM 2024* y publicados en el libro *Telematics and Computing* de la editorial Springer e indizado en Scopus.

2.1.4. Desarrollo y resultados del proyecto

Se desarrolló un asistente para reconocer el estado de conducción, así como una variante del mismo. Estos fueron diseñados para reconocer en tiempo real los estados de conducción segura y en riesgo. Para ello se hizo una revisión del estado del arte y la literatura para conocer las propuestas más actuales en esta temática. De lo cual se observó una mayor tendencia hacia el uso de modelos de aprendizaje profundo convolucionales y recurrentes, así como como el reconocimiento de estado de atención del conductor. Para presentar una propuesta novedosa se optó por utilizar los modelos neuronales *face-detection-retail-0004*, *facial-landmarks-68-160×160* y *head-pose-estimation-adas-0001*, éstos son versiones ligeras que fueron diseñados para funcionamiento en tiempo real. El primero tiene como objetivo principal detectar y delinear el rostro del conductor. El segundo permite detectar los ojos izquierdo y derecho del conductor, así como la boca, para determinar la somnolencia. El tercer modelo permite estimar la postura de la cabeza del conductor para determinar su foco de atención. Para una determinación más estable del

estado de conducción. Para ambos asistentes se hizo el cálculo de los índices de estados de la boca, ojos y la postura de la cabeza; teniendo en cuenta el criterio de juicio de fatiga *Bercios III*. Para el primer asistente se consideró un algoritmo de la fusión multiíndice para reconocer el estado de conducción; mientras que para la segunda variante se consideró un sistema de inferencia difusa Mamdani tipo-1, con objeto de tener un sistema más robusto. Para evaluar el desempeño de estos sistemas, así como de sus componentes se consideraron las métricas *Accuracy*, *Recall*, *Specificity*, *Precision*, y *F1-Score*. Los modelos neuronales tuvieron un desempeño del 89 % al 96 % en todas las métricas, mientras que los componentes de reconocimiento del estado de conducción tuvieron una efectividad del 91 % para el algoritmo de la fusión multiíndice y 93 % para el sistema de inferencia difusa. Con base a estos resultados se escribió un artículo para ser sometido en un congreso internacional, y un artículo para revista indexada en el JCR. El primer manuscrito fue aceptado para su presentación, y publicado en un libro editado por Springer e indexado en Scopus; mientras que el segundo está en estatus de sometido.

Aunado al asistente para monitorear el estado de conducción, se desarrolló a nivel simulación un esquema para la planificación y selección de trayectorias utilizando algoritmos de bajo costo computacional, así como un método de toma de decisiones con múltiples criterios, el cual integró una componente difusa en aras de incluir la experiencia humana al sistema. Este esquema es una propuesta novedosa al estado del arte y la literatura, particularmente en el contexto de los asistentes de conducción enfocados en la planificación y selección de trayectorias. Los vehículos autoconducidos son aplicación de alta complejidad de la Robótica Móvil; aunque en esta área de investigación se han introducido diferentes algoritmos para planificación y seguimiento local y global de trayectorias, éstos no pueden ser usados en el contexto de vehículos autoconducidos principalmente porque estos algoritmos están diseñados para trabajar en el espacio cartesiano (el cual no se apega a las condiciones de curvatura de los carriles de una carretera o autopista). En este sentido, para solventar este problema se trabajó con la teoría local de curvas descrita el espacio de Frenet bidimensional, formalizada a través de los desplazamientos longitudinal y laterales. La generación de trayectorias se hace de manera adaptativa condicionada al espacio de trabajo y obstáculos presentes, en la experimentación se observó el intervalo de $5 \leq \text{trayectorias} \leq 30$ entendido que a menor complejidad del entorno de desplazamiento se tiene un menor número de trayectorias, y éstas tienden a incrementarse en caso contrario. La selección de trayectorias se hizo utilizando la Técnica de Orden de Preferencia por Semejanza a la Solución Ideal (TOPSIS), ésta es una técnica de toma de decisiones basada en múltiples atributos/criterios y múltiples soluciones. Para esta propuesta se sugirió utilizar los criterios: δ ángulo del curso actual del vehículo, ψ ángulo que debe tener el vehículo, ν ángulo de dirección, ϵ distancia del eje central a la trayectoria, ℓ distancia de los ejes del vehículo, R_{vd} distancia entre el vehículo autoconducido y los vehículos cercanos, P posición del vehículo autoconducido

el centro del carril. B_A espacio de frenado de emergencia en relación a la velocidad del vehículo y L_C número de cambios de carril. Para evaluar cuantitativamente el desempeño del método de selección de trayectorias se consideraron las métricas *Eficiencia*, *Seguridad*, *Confort* y el *índice de frecuencia y cambio del cambio de carril (LCFQI)*.

Se trabajó en un artículo "Perfeccionamiento de la técnica TOPSIS y transferencia de conocimientos sobre diferentes estilos de conducción". En este estudio se investigaron métodos de generación de trayectorias para la conducción automatizada mediante la refinación de enfoques existentes que utilizan algoritmos polinómicos y TOPSIS. Aunque la heurística inicial ajustaba los vectores, se exploraron métodos alternativos como la optimización bayesiana y la transferencia de experiencia. La optimización bayesiana logró inicialmente puntuaciones más altas de *Eficiencia* = 0.76 y *Confort* = 0.45, pero la transferencia de experiencia permitió adaptar los estilos de conducción, equilibrando las métricas $0.51 \leq \text{Eficiencia} \leq 0.78$, $0.38 \leq \text{Seguridad} \leq 0.56$, $0.22 \leq \text{Confort} \leq 0.38$ y $0.36 \leq \text{LCFQI} \leq 0.64$ según el estilo de conducción y los obstáculos estáticos. La transferencia de experiencia proporcionó una respuesta más rápida al aprovechar conocimientos previos sin una búsqueda exhaustiva, lo que la convirtió en una opción favorable para implementaciones rápidas y críticas en escenarios de conducción complejos. Este artículo fue aceptado para su presentación en un congreso internacional, y publicado en un libro editado por Springer e indexado en Scopus.

Se trabajó en un artículo "Método de toma de decisiones multiatributo basado en TOPSIS para la selección de trayectorias en un entorno con muchos obstáculos". En este manuscrito se atendieron algunas observaciones recibidas para el artículo anterior, en las cuales se pidió hacer una mejor formulación del método propuesto, así como extender la experimentación, principalmente enfocada en la inclusión de mayores agentes estáticos y dinámicos durante el desplazamiento del vehículo. Se tomó como referencia en estilo conservador de conducción, así como la técnica de transferencia de experiencia en el método de toma de decisiones. El rendimiento del método propuesto se contrastó con respecto a modelos actuales y más avanzados del estado del arte, incluidos LSTM y Deep Q-learning. Los resultados demuestran que el método propuesto logró una mejora del 15 % en la eficiencia y del 20 % en las puntuaciones de seguridad en relación con los métodos comparativos. Además, la incidencia de colisiones se redujo en un 25 %, y el tiempo necesario para una respuesta se redujo en un 12 % en comparación con el modelo LSTM. Los resultados ilustraron la eficacia de nuestra metodología en entornos dinámicos, manteniendo al mismo tiempo la latencia operativa y la adaptabilidad en tiempo real. La capacidad del modelo para equilibrar diversos criterios lo convierte en una solución convincente para aplicaciones de conducción autónoma en entornos reales. Los resultados obtenidos fueron formalizados en un artículo sometido a una revista indexada en el JCR y editada por Springer.

2.1.5. Conclusiones/Observaciones

Conclusiones: El avance del proyecto se corresponde con lo programado para ambos semestres: es de un 100 %. De manera específica, en la formación de recursos humanos se cumplió en su totalidad las metas planeadas para el proyecto. En cuanto a la productividad académica, se presentaron dos artículos en congresos internacionales, los cuales fueron publicados en un libro de la editorial Springer e indizados en Scopus. También se sometieron dos artículos científicos en revistas indizadas en el JCR.

Observaciones: El asistente para planificación y selección de trayectorias se trabajó a nivel simulación, ya que no se dispone de infraestructura para hacerlo a nivel prototipo, aunado a que hay muchos factores del entorno real que aún deben ser analizados a fin de no comprometer la seguridad del conductor.

2.2. Objetivo del proyecto

Examinar y evaluar técnicas de Inteligencia Artificial para desarrollar asistentes de conducción para monitorear el estado de conducción, así como para planificación y selección de la trayectorias, con el fin de prevenir accidentes vehiculares.

2.3. Metas

Metas cuantificables	Cantidad programada	Cantidad lograda	Observaciones
Tesis en desarrollo de Maestría	2	2	Una en desarrollo, y la otra ya se presentaron resultados
Tesis concluida de Maestría	1	1	Titulado con mención honorífica el 28/mayo/2024
Artículos científicos en revistas indizadas enviados	2	2	Ambos fueron sometidos en revistas JCR
Memorias en extenso en congresos	2	2	Ambos presentados en el congreso WITCOM 2024

Metas Cumplidas	
Tesis en desarrollo de Maestría Fecha: 25/junio/2024	Nombre de la tesis: Análisis de algoritmos de visión por computadora para un asistente de carril Ver acuse en el Anexo B
Tesis en desarrollo de Maestría Fecha: 26/junio/2024	Nombre de la tesis: Realce de iluminación para conducción autónoma en escenas nocturnas Ver acuse en el Anexo B
Tesis concluidas de Maestría Fecha: 28/mayo/2024	Nombre de la tesis: Implementación de estrategias avanzadas utilizando TOPSIS para la selección óptima de trayectorias en vehículos autoconducidos Ver acuse en el Anexo C
Artículos científicos enviados en revistas indizadas Fecha: 24/julio/2024	A hybrid deep learning-fuzzy inference scheme for driving supervision sometido en la revista indizada en JCR Inteligencia Artificial con factor de impacto 1.9 A TOPSIS-based multi-attribute decision-making approach for trajectory selection within an obstacle-rich environment sometido en la revista indizada en JCR Applied Soft Computing con factor de impacto 7.2 Ver acuse en el Anexo D
Memorias en extenso en congresos Fecha: 18/julio/2024	Deep learning and index fusion-based driving monitoring system y Fine-Tuning the TOPSIS Technique and Transferring Knowledge of Different Driving Styles presentados en el congreso interencional WITCOM 2024 y publicados en el libro Telematics and Computing de la editorial Springer e indizado en Scopus Ver acuse en el Anexo E

2.4. Metodología

Los procedimientos científico-metodológicos que se siguieron para cumplir los objetivos y metas del proyecto fueron condicionados cronológicamente en función del tipo de asistente. En el primer semestre se trabajó en el asistente para reconocer el estado de conducción, para el segundo semestre se trabajó en el asistente para planificación y selección de trayectorias. Siguiendo este orden:

- Revisión del estado del arte y la literatura sobre las técnicas medulares para el desarrollo de este proyecto de investigación: a) Aprendizaje profundo aplicado al contexto de vehículos autoconducidos, b) Modelado de la arquitectura neuronal *face-detection-retail-0004*, d) Modelado de la arquitectura neuronal *facial-landmarks-68-160x160*, d) Modelado de la arquitectura neuronal *head-pose-estimation-adas-0001*, e) criterio de juicio de fatiga *perclos*, e) Inferencia difusa basados en reglas y f) Desarrollo de sistemas embebidos basada en unidades de procesamiento gráfico de alto rendimiento.
- Programación de los modelos neuronales basados en visión por computadora elegidos para para la

sección de los ojos, boca y postura de la cabeza.

- Integración en un sistema embebido de alto rendimiento de las arquitecturas neuronales seleccionadas, así como una técnica neurística para reconocimiento del estado de conducción.
- Diseño de un módulo de inferencia difusa basado en reglas, que considera como entradas la información suministrada por las arquitecturas neuronales modeladas, y como salida el estado de conducción.
- Estimación del rendimiento de los sistemas para reconocimiento del estado de conducción desarrollados, así como comparación del desempeño de estos sistemas con otras propuestas existentes en la literatura.
- Elaboración de dos artículos considerando los resultados obtenidos, así como su sometimiento en un congreso internacional y en una revista indizada en el JCR, en concordancia con las metas establecidas.
- En la Teoría de Curvas se investigó y analizó la conceptualización matemática del sistema de Frenet, extrapolaron esos conceptos en la tarea de planificación local de trayectorias utilizable en vehículos autoconducidos. Sin embargo, solo se generaron los puntos iniciales y finales de la trayectoria, por consiguiente para el trazado de las trayectorias se consideró el método de interpolación polinomial de quinto orden.
- Se revisó el estado del arte y la literatura sobre algoritmos para toma de decisiones basados en múltiples criterios, se observó que éstos originalmente fueron diseñados utilizando matemáticas discretas mediante teoría binaria de números, sin embargo han sido mayormente estudiados y formulados a partir de la teoría de conjuntos difusos a través de los diferentes tipos de números difusos introducidos, ya que permiten solventar problemas de información ambigua o con incertidumbre. Aunado a lo anterior, se observó que este tipo de técnicas son usados principalmente en mundo de los negocios/finanzas de las organizaciones o empresas, el gobierno, la salud, la educación y la toma de decisiones personales; lo cual nos permite ser pioneros en el uso de este tipo de algoritmos en el contexto de los vehículos autoconducidos.
- Para diseñar y desarrollar el método para la selección de trayectoria utilizando la Técnica de Orden de Preferencia por Semejanza a la Solución Ideal se asumió que las soluciones son todas las trayectorias generadas y trazadas en el espacio de Frenet, éstas fueron ponderadas y ordenadas considerando los criterios $[\delta, \psi, \nu, \epsilon, \ell, R_{vd}, P, B_d, L_C]$. La solución ideal fue aquella con el tango más alto; en otras

9 9 10 9

palabras, la solución ideal fue aquella trayectoria que implicó el menor riesgo de provocar una colisión. Esta técnica fue programada en Matlab, considerando los *Toolboxes: Fuzzy Logic, Automated Driving, Robotics System, Navigation, Sensor Fusion and Tracking* para hacer la simulación del vehículo autonconducido, de los vehículos con quienes se interactuó, carreteras, la percepción visual del entorno y el control del desplazamiento del vehículo autoconducido.

- Se elaboró un artículo para congreso internacional y un artículo para revista indizadas en el JCR. Con lo cual se cubrieron todas las metas establecidas en términos de producción científica.

2.5. Difusión

La difusión de los resultados obtenidos por los sistemas desarrollados se realizará durante la participación en los congresos internacionales en los fueron aceptados los trabajos para su presentación, se considera que haya interacción con investigadores y estudiantes de otras instituciones del país. También se hará a través los artículos una vez que sean publicados, así como el compartirlos mediante foros como Reseachgate, github, etc.

2.6. Beneficios y Problemas

Los resultados de este proyecto contribuyen en aspectos importantes a nivel institucional, departamental y personal, de manera concreta:


1. Una de las metas principales del CENIDET es que sus programas cumplan con los estándares del Sistema Nacional de Posgrado del Conahcyt; así como mejorar su calidad en forma continua. Esto se logra con áreas de investigación en el estado del arte en temas relevantes que puedan ser publicados en revistas de prestigio. Los resultados obtenidos en este trabajo permiten avanzar en el conocimiento de un área que cuenta con diversos foros de publicación: la inteligencia artificial, aprendizaje profundo, vision robotica, vehiculos autonomos/autoconducidos, así como la teoría difusa. Este avance en el estado del arte permitirá que el CENIDET tenga una ventaja competitiva con otros centros que realizan investigación en estas areas de las ciencias. tanto en articulos investigación y en la mejora de la formación de recursos humanos altamente especializados.
2. Los sistemas desarrollados y resultados obtenidos permiten avanzar en los temas recurrentes y emergentes que son de importancia para el Departamento de Ciencias Computacionales así como la LGAC de Tecnologías Inteligentes de Software: la inteligencia artificial, aprendizaje profundo,

en robótica, vehículos autónomos/autoconducidos, así como la teoría difusa. También se espera la consolidación de estos temas de investigación, lo cual permitirá el aumento en la producción científica y la vinculación con otras instituciones.

3. Para los estudiantes participantes y el profesor-investigador responsable del proyecto, adquirir mayor experiencia en el área emergente de vehículos auto-conducidos, también conocida como vehículos autónomos, y con el fin de abrir un área de investigación para formación de estudiantes en áreas interdisciplinarias.
4. Para el profesor-investigador Dante Mújica Vargas responsable de este proyecto de investigación, incrementar la productividad científica de artículos y formación de recursos humanos, de tal forma que pueda permanecer en el nivel II del SNI.

2.7. Información adicional

En el Anexo F se presentan evidencias de las actividades realizadas en la institución receptora.

Subdirector Académico	Docente
 Dr. Carlos Manuel Astorga Zaragoza	 Dr. Dante Mújica Vargas

Referencias

- [1] A. Acioğlu and E. Ercelebi, "Real time eye detection algorithm for perclos calculation," in *2016 24th Signal Processing and Communication Application Conference (SIU)*. IEEE, 2016, pp. 1641–1644.
- [2] T. Zhu, C. Zhang, T. Wu, Z. Ouyang, H. Li, X. Na, J. Liang, and W. Li, "Research on a real-time driver fatigue detection algorithm based on facial video sequences," *Applied Sciences*, vol. 12, no. 4, p. 2224, 2022.
- [3] J. A. Alzubi, R. Jain, O. Alzubi, A. Thareja, and Y. Upadhyay, "Distracted driver detection using compressed energy efficient convolutional neural network," *Journal of Intelligent & Fuzzy Systems*, vol. 42, no. 2, pp. 1253–1265, 2022.
- [4] V. U. Maheswari, R. Aluvalu, M. P. Kantipudi, K. K. Chennam, K. Kotecha, and J. R. Saini, "Driver drowsiness prediction based on multiple aspects using image processing techniques," *IEEE Access*, vol. 10, pp. 54 980–54 990, 2022.
- [5] L. Chen, G. Xin, Y. Liu, and J. Huang, "Driver fatigue detection based on facial key points and lstm," *Security and Communication Networks*, vol. 2021, pp. 1–9, 2021.
- [6] I. Jahan, K. A. Uddin, S. A. Murad, M. S. U. Miah, T. Z. Khan, M. Masud, S. Aljahdali, and A. K. Bairagi, "4d: a real-time driver drowsiness detector using deep learning," *Electronics*, vol. 12, no. 1, p. 235, 2023.
- [7] D. Yang, Y. Wang, R. Wei, J. Guan, X. Huang, W. Cai, and Z. Jiang, "An efficient multi-task learning cnn for driver attention monitoring," *Journal of Systems Architecture*, p. 103085, 2024.
- [8] T. Akiduki, J. Nagasawa, Z. Zhang, Y. Omae, T. Arakawa, and H. Takahashi, "Inattentive driving detection using body-worn sensors: feasibility study," *Sensors*, vol. 22, no. 1, p. 352, 2022.
- [9] H. Shi, L. Chen, X. Wang, G. Wang, and Q. Wang, "A nonintrusive and real-time classification method for driver's gaze region using an rgb camera," *Sustainability*, vol. 14, no. 1, p. 508, 2022.
- [10] A. Kashevnik, R. Shchedrin, C. Kaiser, and A. Stocker, "Driver distraction detection methods: A literature review and framework," *IEEE Access*, vol. 9, pp. 60 063–60 076, 2021.
- [11] A. Halin, J. G. Verly, and M. Van Droogenbroeck, "Survey and synthesis of state of the art in driver monitoring," *Sensors*, vol. 21, no. 16, p. 5558, 2021.

- [12] F. M. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally, and K. Keutzer, "Squeezenet: Alexnet-level accuracy with 50x fewer parameters and <0.5 mb model size," *arXiv preprint arXiv:1602.07360*, 2016.
- [13] Intel. (2024) Openvino™ toolkit. [Online]. Available: github.com/openvinotoolkit/openvino
- [14] X. Zhang, X. Zhou, M. Lin, and J. Sun, "Shufflenet: An extremely efficient convolutional neural network for mobile devices," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 6847–6855.
- [15] S. Yang, P. Luo, C. C. Loy, and X. Tang, "Wider face: A face detection benchmark," in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016.
- [16] C. Sagonas, G. Tzimiropoulos, S. Zafeiriou, and M. Pantic, "300 faces in-the-wild challenge: The first facial landmark localization challenge," in *Proceedings of the IEEE international conference on computer vision workshops*, 2013, pp. 397–403.
- [17] G. Fanelli, M. Dantone, J. Gall, A. Fossati, and L. Van Gool, "Random forests for real time 3d face analysis," *International journal of computer vision*, vol. 101, pp. 437–458, 2013.
- [18] M. Omidyeganeh, S. Shirmohammadi, S. Abtahi, A. Khurshid, M. Farhan, J. Scharcanski, B. Hariri, D. Laroche, and L. Martel, "Yawning detection using embedded smart cameras," *IEEE Transactions on Instrumentation and Measurement*, vol. 65, no. 3, pp. 570–582, 2016.
- [19] A. Ghourabi, H. Ghazouani, and W. Barhoumi, "Driver drowsiness detection based on joint monitoring of yawning, blinking and nodding," in *2020 IEEE 16th International Conference on Intelligent Computer Communication and Processing (ICCP)*. IEEE, 2020, pp. 407–414.
- [20] H. Jia, Z. Xiao, and P. Ji, "Fatigue driving detection based on deep learning and multi-index fusion," *IEEE Access*, vol. 9, pp. 147 054–147 062, 2021.
- [21] M. Dai and S.-G. Lee, "Perception, planning and control for self-driving system based on on-board sensors," *Advances in Mechanical Engineering*, vol. 12, no. 9, p. 1687814020956494, 2020.
- [22] F. Xiao, Z. Cao, and A. Jolfaei, "A novel conflict measurement in decision-making and its application in fault diagnosis," *IEEE Transactions on Fuzzy Systems*, vol. 29, no. 1, pp. 186–197, 2020.
- [23] S. Zhang, Z. Sun, M. Wang, J. Long, Y. Bai, and C. Li, "Deep fuzzy echo state networks for machinery fault diagnosis," *IEEE Transactions on Fuzzy Systems*, vol. 28, no. 7, pp. 1205–1218, 2019.

- [24] H. T. Alyas, G. Ahmad, Y. Saeed, M. Asif, U. Farooq, and A. Kanwal, "Cloud and iot based smart car parking system by using mamdani fuzzy inference system (mfis)," *ISeCure*, vol. 11, no. 3, 2019.
- [25] Q. Mao, L. Dou, Z. Yang, B. Tian, and Q. Zong, "Fuzzy disturbance observer-based adaptive sliding mode control for reusable launch vehicles with aeroservoelastic characteristic," *IEEE Transactions on Industrial Informatics*, vol. 16, no. 2, pp. 1214–1223, 2019.
- [26] G. Li, Y. Chen, D. Cao, X. Qu, B. Chen, and K. Li, "Extraction of descriptive driving patterns from driving data using unsupervised algorithms," *Mechanical Systems and Signal Processing*, vol. 156, p. 107589, 2021.
- [27] D. Dörr, D. Grabengieser, and F. Gauterin, "Online driving style recognition using fuzzy logic," in *17th international IEEE conference on intelligent transportation systems (ITSC)*. IEEE, 2014, pp. 1021–1026.
- [28] A. Aljaafreh, N. Alshabat, and M. S. N. Al-Din, "Driving style recognition using fuzzy logic," in *2012 IEEE international Conference on Vehicular Electronics and Safety (ICVES 2012)*. IEEE, 2012, pp. 460–463.
- [29] H. Hao, W. Ma, and H. Xu, "A fuzzy logic-based multi-agent car-following model," *Transportation Research Part C: Emerging Technologies*, vol. 69, pp. 477–496, 2016.
- [30] J. M. Mendel, *Explainable Uncertain Rule-Based Fuzzy Systems*. Springer, 2023.
- [31] M. Werling, J. Ziegler, S. Kammel, and S. Thrun, "Optimal trajectory generation for dynamic street scenarios in a frenet frame," in *2010 IEEE international conference on robotics and automation*. IEEE, 2010, pp. 987–993.
- [32] K. Yoneda, T. Iida, T. Kim, R. Yanase, M. Aldibaja, and N. Suganuma, "Trajectory optimization and state selection for urban automated driving," *Artificial Life and Robotics*, vol. 23, no. 4, pp. 411–420, 2018.
- [33] P. Hang, C. Lv, Y. Xing, C. Huang, and Z. Hu, "Human-like decision making for autonomous driving: A noncooperative game theoretic approach," *IEEE Transactions on Intelligent Transportation Systems*, vol. 22, no. 4, pp. 2076–2087, 2021.
- [34] H. Wang, A. Khajepour, D. Cao, and T. Liu, "Ethical decision making in autonomous vehicles: Challenges and research progress," *IEEE Intelligent Transportation Systems Magazine*, vol. 14, no. 1, pp. 6–17, 2022.

- [35] M. Lindorfer, C. F. Mecklenbraeuer, and G. Ostermayer, "Modeling the imperfect driver: Incorporating human factors in a microscopic traffic model," *IEEE Transactions on Intelligent Transportation Systems*, vol. 19, no. 9, pp. 2856–2870, 2018.
- [36] S. Moon and K. Yi, "Human driving data-based design of a vehicle adaptive cruise control algorithm," *Vehicle System Dynamics*, vol. 46, no. 8, pp. 661–690, 2018.
- [37] C. Guo, K. Kidono, R. Terashima, and Y. Kojima, "Toward human-like behavior generation in urban environment based on markov decision process with hybrid potential maps," in *2018 IEEE Intelligent Vehicles Symposium (IV)*. IEEE, 2022, pp. 2209–2215.
- [38] H. Bai, S. Cai, N. Ye, D. Hsu, and W. S. Lee, "Intention-aware online pomdp planning for autonomous driving in a crowd," in *2023 IEEE International Conference on Robotics and Automation (ICRA)*. IEEE, 2023, pp. 454–460.
- [39] R. Schubert, "Evaluating the utility of driving: Toward automated decision making under uncertainty," *IEEE Transactions on Intelligent Transportation Systems*, vol. 13, no. 1, pp. 354–364, 2021.
- [40] S. Noh, "Decision-making framework for autonomous driving at road intersections: Safeguarding against collision, overly conservative behavior, and violation vehicles," *IEEE Transactions on Industrial Electronics*, vol. 66, no. 4, pp. 3275–3286, 2023.
- [41] A. Furda and L. Vlacic, "Enabling safe autonomous driving in real-world city traffic using multiple criteria decision making," *IEEE Intelligent Transportation Systems Magazine*, vol. 3, no. 1, pp. 4–17, 2021.
- [42] J. Chen, P. Zhao, H. Liang, and T. Mei, "A multiple attribute-based decision making model for autonomous vehicle in urban environment," in *2014 IEEE Intelligent Vehicles Symposium Proceedings*. IEEE, 2023, pp. 480–485.
- [43] J. Nie, J. Zhang, W. Ding, X. Wan, X. Chen, and B. Ran, "Decentralized cooperative lane-changing decision-making for connected autonomous vehicles," *IEEE Access*, vol. 4, pp. 9413–9420, 2022.
- [44] A. Eskandarian, C. Wu, and C. Sun, "Research advances and challenges of autonomous and connected ground vehicles," *IEEE Transactions on Intelligent Transportation Systems*, vol. 22, no. 2, pp. 683–711, 2019.
- [45] J. Rios-Torres and A. A. Malikopoulos, "Automated and cooperative vehicle merging at highway on-ramps," *IEEE Transactions on Intelligent Transportation Systems*, vol. 18, no. 4, pp. 780–789, 2022.

- [46] J. Ding, H. Peng, Y. Zhang, and L. Li, "Penetration effect of connected and automated vehicles on cooperative on-ramp merging," *IET Intelligent Transport Systems*, vol. 14, no. 1, pp. 56–64, 2020.
- [47] C. Liu, C.-W. Lin, S. Shiraishi, and M. Tomizuka, "Distributed conflict resolution for connected autonomous vehicles," *IEEE Transactions on Intelligent Vehicles*, vol. 3, no. 1, pp. 18–29, 2019.
- [48] L. Xu, J. Lu, B. Ran, F. Yang, and J. Zhang, "Cooperative merging strategy for connected vehicles at highway on-ramps," *Journal of Transportation Engineering, Part A: Systems*, vol. 145, no. 6, p. 04019022, 2019.
- [49] Y. Wang, W. E. W. Tang, D. Tian, G. Lu, and G. Yu, "Automated on-ramp merging control algorithm based on internet-connected vehicles," *IET Intelligent Transport Systems*, vol. 7, no. 4, pp. 571–579, 2023.
- [50] T. Harris, "Credit scoring using the clustered support vector machine," *Expert Systems with Applications*, vol. 42, no. 2, pp. 741–750, 2021.
- [51] P. Wu, S. Chen, and D. N. Metaxas, "Motionnet: Joint perception and motion prediction for autonomous driving based on bird's eye view maps," in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2022, pp. 11 385–11 395.
- [52] Z. Huang, J. Wu, and C. Lv, "Driving behavior modeling using naturalistic human driving data with inverse reinforcement learning," *IEEE transactions on intelligent transportation systems*, vol. 23, no. 8, pp. 10 239–10 251, 2021.
- [53] Y. Liu, X. Wang, L. Li, S. Cheng, and Z. Chen, "A novel lane change decision-making model of autonomous vehicle based on support vector machine," *IEEE access*, vol. 7, pp. 26 543–26 550, 2023.
- [54] L. Li, K. Ota, and M. Dong, "Humanlike driving: Empirical decision-making system for autonomous vehicles," *IEEE Transactions on Vehicular Technology*, vol. 67, no. 8, pp. 6814–6823, 2022.
- [55] X. Gu, Y. Han, and J. Yu, "A novel lane-changing decision model for autonomous vehicles based on deep autoencoder network and xgboost," *IEEE Access*, vol. 8, pp. 9846–9863, 2021.
- [56] R. Zheng, C. Liu, and Q. Guo, "A decision-making method for autonomous vehicles based on simulation and reinforcement learning," in *2023 International Conference on Machine Learning and Cybernetics*, vol. 1. IEEE, 2023, pp. 362–369.



- [57] J. Lu, D. Filev, and P. Tsiotras, "Highway traffic modeling and decision making for autonomous vehicle using reinforcement learning," in *2023 IEEE Intelligent Vehicles Symposium (IV)*. IEEE, 2023, pp. 1337–1342.
- [58] S. M. Veres, L. Molnar, N. K. Lincoln, and C. P. Morice, "Autonomous vehicle control systems—a review of decision making," *Proceedings of the Institution of Mechanical Engineers. Part I: Journal of Systems and Control Engineering*, vol. 225, no. 2, pp. 155–195, 2021.
- [59] J. Chen, B. Yuan, and M. Tomizuka, "Model-free deep reinforcement learning for urban autonomous driving," in *2023 IEEE intelligent transportation systems conference (ITSC)*. IEEE, 2023, pp. 2765–2771.
- [60] F. Gritschneider, P. Hatzelmann, M. Thom, F. Kunz, and K. Dietmayer, "Adaptive learning based on guided exploration for decision making at roundabouts," in *2022 IEEE intelligent vehicles symposium (IV)*. IEEE, 2022, pp. 433–440.
- [61] H. Yu, H. E. Tseng, and R. Langari, "A human-like game theory-based controller for automatic lane changing," *Transportation Research Part C: Emerging Technologies*, vol. 88, pp. 140–158, 2020.
- [62] S. Pan, Y. Wang, and K. Wang, "A game theory-based model predictive controller for mandatory lane change of multiple vehicles," in *2020 4th CAA International Conference on Vehicular Control and Intelligence (CVCI)*. IEEE, 2020, pp. 731–736.
- [63] H. Wang, S. Xu, and L. Deng, "Automatic lane-changing decision based on single-step dynamic game with incomplete information and collision-free path planning," in *Actuators*, vol. 10, no. 8. MDPI, 2021, p. 173.
- [64] C. Xu, W. Zhao, L. Li, Q. Chen, D. Kuang, and J. Zhou, "A nash q-learning based motion decision algorithm with considering interaction to traffic participants," *IEEE Transactions on Vehicular Technology*, vol. 69, no. 11, pp. 12 621–12 634, 2020.
- [65] S. Pruekprasert, J. Dubut, X. Zhang, C. Huang, and M. Kishida, "A game-theoretic approach to decision making for multiple vehicles at roundabout," *arXiv preprint arXiv:1904.06224*, 2023.
- [66] Y. Ali, Z. Zheng, M. M. Haque, and M. Wang, "A game theory-based approach for modelling mandatory lane-changing behaviour in a connected environment," *Transportation research part C: emerging technologies*, vol. 106, pp. 220–242, 2019.

- [71] R. Tian, S. Li, N. Li, I. Kolmanovskiy, A. Girard, and Y. Yildiz, "Adaptive game-theoretic decision making for autonomous vehicle control at roundabouts," in *2022 IEEE conference on decision and control (CDC)*, IEEE, 2022, pp. 6211–12.
- [68] S. Jin, F. Hui, X. Zhao, J. Rios-Torres, and A. J. Khattak, "Cooperative game approach to optimal merging sequence and on-ramp merging control of connected and automated vehicles," *IEEE Transactions on Intelligent Transportation Systems*, vol. 20, no. 11, pp. 4234–4244, 2019.
- [69] A. Sorniotti, P. Barber, and S. De Pinto, "Path tracking for automated driving: A tutorial on control system formulations and ongoing research," *Automated driving: Safer and more efficient future driving*, pp. 71–140, 2017.
- [70] X. Gao, X. Li, Q. Liu, Z. Li, F. Yang, and T. Luan, "Multi-agent decision-making modes in uncertain interactive traffic scenarios via graph convolution-based deep reinforcement learning," *IEEE Transactions on Intelligent Transportation Systems*, vol. 22, no. 12, p. 4586, 2020.
- [71] T. M. Inc., "Automated driving toolbox," Natick, Massachusetts, United States, 2024a. [Online]. Available: <https://www.mathworks.com/help/driving/index.html>
- [72] K. Thompson, "Next generation simulation (ngsim) vehicle trajectories and supporting data," *Data set*, 2022.
- [73] X. Tang, G. Zhong, K. Yang, J. Wu, and Z. Wei, "Motion planning framework for autonomous vehicle with lstm-based predictive model," in *2021 5th CAA International Conference on Vehicular Control and Intelligence (CVCI)*, 2021, pp. 1–5.
- [74] Z. Wang, H. Yan, C. Wei, J. Wang, S. Bo, and M. Xiao, "Research on autonomous driving decision-making strategies based deep reinforcement learning," *arXiv preprint arXiv:2408.03084*, 2024.

Anexos

1

2

3

Actividades desarrolladas

A.1. Revisión del estado del arte sobre modelos de Aprendizaje Profundo

Como resultado de la revisión en el estado del arte y la literatura se observó que la mayoría de las propuestas actuales están centradas en supervisar el estado de atención del conductor. En este ámbito se han realizado importantes contribuciones, de las cuales se puede hacer alusión a las siguientes:

En [2], se introdujo un algoritmo en tiempo real para detectar el estado de fatiga del conductor utilizando secuencias de video faciales sin necesidad de equipar el cuerpo del conductor con otro tipo de dispositivos inteligentes. En [3] se presentó un enfoque novedoso para detectar la distracción del conductor usando dispositivos electrónicos portátiles, la propuesta era una versión más ligera de una CNN, con un rendimiento de precisión de 0.83 con un número reducido de parámetros del modelo. En [4], se utilizó una CNN para desarrollar un esquema computacional para predecir la fatiga del conductor, teniendo en cuenta en cuenta factores como los ojos cerrados, la boca abierta, las manos sobre los ojos o la boca durante, así como inclinación de la cabeza. En [5], los autores hicieron la detección de fatiga utilizando los puntos clave faciales y una red neuronal profunda LSTM, y también desarrollaron la detección de fatiga basada en las frecuencias de parpadeo y bostezo calculadas a partir de los estados temporales de los ojos y la boca. En [6], se evaluó la capacidad de cuatro modelos de CNN para categorizar estados oculares; además, se incluyó en el sistema una alerta sonora para notificar al conductor si entraba en una fase de somnolencia. En [7], se introdujo una red CNN con aprendizaje multitarea y con parámetros compartidos. Este enfoque permitía la salida simultánea del punto de referencia de la cara del conductor, la pose de la cabeza y la dirección de la mirada a través de tres ramas. Una vez detectado el punto de referencia facial, se calcularon estados como la frecuencia de bostezos y parpadeos, la duración de los parpadeos y la apertura y cierre de ojos. En [8] se desarrolló un sistema para detectar el estado interno de un conductor utilizando sensores corporales. Este sistema combinaba tres modelos de detección: movimiento corporal, somnolencia y detección de falta de atención. Los modelos de detección se basaban en un algoritmo de detección de anomalías basado en un control de procesos estadístico multivariante. En [9], se introdujo un método de clasificación no intrusivo y en tiempo real para la región de la mirada del conductor. Este método emplea una cámara RGB y utiliza una CNN para la detección facial, así como una red GazeNet para la estimación de la mirada. En [10, 11], se presentó una revisión de la literatura y un marco de referencia en cuanto a propuestas abordadas para detectar la distracción del conductor, de estos trabajos se resalta el uso del aprendizaje profundo como las técnicas más usadas en la actualidad, pero en general, solo enfocadas de detectar la somnolencia del conductor, en detectar el punto de atención/distracción

El conductor.

Del análisis de estos estudios se desprende que varios aspectos merecen ser mencionados. La mayoría de estos estudios se basan en el paradigma del aprendizaje profundo, con especial atención a las redes CNN y RNN. Todos estos estudios tienen como objetivo detectar la fatiga del conductor mediante el uso de análisis de video facial. En algunos casos, se emplea el uso de sensores vestibles e incluso sistemas invasivos. El objetivo principal de estos estudios fue detectar la somnolencia del conductor. Por tanto para el presente proyecto de investigación y a diferencia de las propuestas mencionadas, se detectó la somnolencia del conductor como un medio para inferir el estado de la conducción, es decir, si es segura o insegura, como consecuencia de la distracción.

A.2. Modelos seleccionados y estimación de su rendimiento

Como resultado de la revisión del estado del arte y la literatura se observó que la mayoría de las propuestas actuales están centradas en supervisar el estado de atención del conductor. En este ámbito se han realizado importantes contribuciones, de las cuales se puede hacer alusión a las siguientes:

face-detection-retail-0004

La detección de rostros en imágenes/videos captadas por una cámara frontal se realizó utilizando un modelo ligero de la red SqueezeNet [12], esta variante fue diseñada para detectar objetos, a diferencia del modelo original el cual fue diseñado para clasificar objetos. La arquitectura de este modelo se representa en la Figura A.1, como puede observarse, la columna vertebral de este modelo se compone de módulos llamados *fire* que sirven para reducir el número de cálculos necesarios [13]. El modelo acepta como entrada una secuencia de imágenes con formato $[Batch\ Size \times Number\ of\ Channels \times ImageHeight \times ImageWidth]$, considerando la dimensionalidad $[1 \times 3 \times 300 \times 300]$. Este formato se emplea para garantizar que se mantengan las dimensiones de imagen requeridas, también se incluye un bloque de escalado para facilitar este proceso. Tras el redimensionamiento, *SqueezeNet light* se inicia con una capa de convolución independiente, seguida de once módulos de disparo. Estos módulos comprenden capas de convolución de compresión (con filtros de tamaño 1×1) que alimentan una capa de expansión que tiene una mezcla de filtros de convolución 1×1 y 3×3 [12]. Todas las capas de compresión imponen un límite al número de entradas de los filtros 3×3 , ya que la función de los filtros 1×1 es la reducción dimensional (limitar el número de canales). El módulo de disparo emplea un bloque de concatenación para conectar diferentes capas, aumentando así la capacidad de representación. Esto está relacionado con la extracción de información espacial/características de las imágenes, como se ha comentado previamente. La salida del

undécimo módulo de disparo se emplea como entrada para dos ramas, la abstracción fina de características y el bloque de agrupación de bloques previos, considerando los tamaños especificados. El último paso del algoritmo es la supresión no máxima del bloque de salida de detección, que genera el resultado de la detección utilizando información sobre la ubicación y predicciones de confianza. La red produce una salida que es un tensor con forma: $[1, 1, N, 7]$, donde N es el número de recuadros delimitadores detectados. Para cada detección, se tiene el formato: $[image_{id}, label, conf, x_{min}, y_{min}, x_{max}, y_{max}]$. Concretamente, esta investigación utiliza los datos $x_{min}, y_{min}, x_{max}, y_{max}$, porque se utilizan para delinear la cara del conductor.




Figura A.1: face-detection-retail-0004.

facial-landmarks-68-160×160

Se trata de una red neuronal convolucional personalizada diseñada para la estimación de 68 puntos de referencia faciales; en este sentido, los más relevantes para el estudio actual son los que describen tanto

los ojos como la boca. El modelo se presenta en la Figura A.2, éste es una derivación de la red Shufflenet Network v2. Se trata de una red neuronal convolucional muy eficaz para dispositivos móviles, como se demuestra en [14].




Figura A.2: Model: *facial-landmarks-68-160x160*.

El objetivo principal de este modelo es implementar la codificación y decodificación de las coordenadas x e y utilizando el mapa térmico y los valores de desplazamiento para x e y . Al igual que en el proceso de detección de objetos, el mapa térmico sirve para identificar qué punto del el mapa de características es la muestra positiva. Esto se representa mediante un área resaltada, con los desplazamientos x e y responsables de determinar las coordenadas precisas de las muestras positivas en cuestión. El modelo recibe una imagen/video en formato $[Batch\ Size \times Number\ of\ Channels \times ImageHeight \times ImageWidth]$, con valores específicos $[1 \times 3 \times 160 \times 160]$. El modelo incorpora las operaciones *fused Mul* y *fused Add*, las cuales sirven para mejorar el desempeño computacional. Además, incluye las operaciones aritméticas y espaciales *matMul*, *MatAdd* and *Mean*. Los módulos *Shufflenet*, basados en unidades *Shufflenet*, constituyen la base de este modelo, éstos implican una mezcla de canales para grupos de convoluciones, que pueden describirse como mezclas separables en profundidad o mezclas de grupos. Estos bloques llevan a cabo operaciones de convolución en profundidad, strided slicing y concatenación. En resumen, la

Convolucion en profundidad es un tipo de convolución en el que se aplica un único filtro convolucional a cada canal de entrada, mientras que la convolución 2D normal se realiza sobre varios canales de entrada. El filtro es tan profundo como la entrada, y permite mezclar los canales para generar cada elemento en la salida. En cambio, las convoluciones en profundidad mantienen el carácter distintivo de cada canal. La operación *StridedSlice* extrae un vector de un tensor dado basándose en índices calculados a partir de las entradas: *begin* (incluyendo el elemento en el índice dado), *end* (excluyendo el elemento en el índice dado), y *stride* para cada dimensión [13].

head-pose-estimation-adas-0001

La red *head-pose-estimation-adas-0001* es una arquitectura convolucional diseñada de manera artesanal [13], tal como se muestra en la Figura A.3. Este modelo realiza operaciones básicas de una red neuronal convolucional, de las que se pueden mencionar las convoluciones para la abstracción de características, el *pooling* para el submuestreo de la información, la normalización de lotes para realizar las siguientes operaciones en un lote de datos dado de entrada de datos tensoriales, y *dropping out* para ayudar a reducir la norma cuadrática de los pesos, esto tiende a reducir el sobreajuste durante el entrenamiento.




Figura A.3: *head-pose-estimation-adas-0001*.

Entrenamiento

El modelo *face-detection-retail-0004* fue entrenado con la base de datos *Wider Face dataset* [15], esta fue diseñada para la tarea de detección facial, se consideraron 32,203 instancias para el entrenamiento, aunque la base contiene etiquetados 393,703 rostros con un alto grado de variabilidad en escala, pose y oclusión. Por otro parte, el modelo *facial-landmarks-68-160x160* fue entrenado con la base de datos 300VW [16], éste consiste en 300 video con la tarea de seguimiento de rostros, cada video tiene una duración aproximada de ~ 1 minuto a 25-30 fps. Finalmente, el modelo *head-pose-estimation-adas-0001* fue entrenado con la base de datos *Biwi Kinect Head Pose Database* [17], en cual 15K imágenes de 20 personas fueron capturados utilizando un sensor RGBD, mientras giraban libremente sus cabezas. Para cada instancia se proporciona la referencia de la profundidad, las imágenes RGB, así como la posición 3D de la cabeza considerando sus ángulos de rotación. Para facilitar la identificación, estos tres modelos se denominan *Modelo 1*, *Modelo 2*, y *Modelo 3*, respectivamente.

Estimación del rendimiento

Para evaluar el rendimiento de los tres modelos neuronales se consideró un experimento para reconocer la cara, ojos, boca, así como la postura de la cabeza, en concordancia con la tarea para la que fueron diseñados estos modelos convolucionales. El experimento se realizó capturando 50 vídeos de muestra de aproximadamente un minuto de duración a 30 fps y 1080x1080 de resolución de vídeo. Para proporcionar una evaluación cuantitativa del rendimiento, se consideraron las métricas *Accuracy*, *Recall*, *Specificity*, *Precision* y *F1-Score*. Por otra parte, para tener una referencia del rendimiento de estos modelos evaluados, se consideraron métodos populares de la literatura como medio de contraste. Las Tablas A.1~A.4 resumen los resultados obtenidos utilizando los valores medianos en lugar de los valores medios, ya que constituyen una estimación más robusta.

Tabla A.1: Tarea de reconocimiento facial

Task	Methodology	Accuracy	Recall	Specificity	Precision	F1-Score
Face recognition	Viola-Jones [18]	0.907	0.911	0.899	0.920	0.874
	HoG [19]	0.909	0.915	0.902	0.896	0.862
	MTCNN [5]	0.917	0.912	0.918	0.909	0.885
	TDCNN [2]	0.929	0.935	0.902	0.908	0.887
	Model 1	0.957	0.963	0.954	0.968	0.927

Tabla A.2: Tarea del reconocimiento de los ojos

Task	Methodology	Accuracy	Recall	Specificity	Precision	F1-Score
Eye state recognition	Viola-Jones+EAR	0.897	0.886	0.898	0.865	0.881
	MTCNN+DLIB+EAR	0.901	0.882	0.901	0.879	0.828
	4D model+EAR[6]	0.910	0.896	0.904	0.897	0.868
	E-MSR[20]	0.920	0.909	0.918	0.907	0.883
	Model 2 + EAR	0.935	0.935	0.949	0.931	0.908

Tabla A.3: Tarea del reconocimiento de la boca

Task	Methodology	Accuracy	Recall	Specificity	Precision	F1-Score
Mouth state recognition	Viola-Jones+MOR	0.865	0.845	0.854	0.861	0.821
	MTCNN+DLIB+MOR	0.851	0.865	0.876	0.879	0.838
	4D model+MOR	0.870	0.908	0.906	0.901	0.863
	E-MSR	0.894	0.902	0.908	0.890	0.865
	Model 2 + MOR	0.929	0.918	0.920	0.919	0.903

Tabla A.4: Tarea de reconocimiento de la postura de la cabeza

Task	Methodology	Accuracy	Recall	Specificity	Precision	F1-Score
Head posture recognition	Viola-Jones	0.871	0.860	0.866	0.857	0.818
	MTCNN+DLIB	0.875	0.853	0.871	0.859	0.826
	E-MSR	0.897	0.874	0.887	0.863	0.823
	TCDCN	0.890	0.874	0.895	0.884	0.827
	Model 3	0.919	0.925	0.922	0.903	0.898

Se observa que los resultados más estables y con los valores más altos (todos oscilan entre 0.898 y 0.968) se obtuvieron por los métodos elegidos como soporte de la propuesta de esta investigación. Es importante señalar que, a medida que aumenta el nivel de complejidad de una tarea determinada, los resultados muestran una reducción perceptible. Por ejemplo, en el reconocimiento de caras, el área de trabajo abarca una extensión mayor que la ocupada por los ojos o la boca, lo que permite obtener resultados superiores en todos los métodos evaluados. En cuanto a las tareas de reconocimiento de los ojos y la boca, resulta evidente que la mayoría de las propuestas se basan en la combinación de al menos dos técnicas. Para la detección de la postura de la cabeza, en la propuesta actual se consideraron los movimientos de mirar hacia abajo, girar a la derecha y girar a la izquierda, ya que son indicativos de una posible pérdida de atención del conductor a la zona de desplazamiento del vehículo. Este enfoque difiere de los demás estudios de investigación, que se centraban únicamente en el movimiento de mirar hacia abajo.

27

A.3. Revisión del estado del arte sobre sistemas de inferencia difusa

En el estado del arte y la literatura relacionada con vehículos autónomos sobresale el uso de la lógica difusa en tareas de control de movimiento, detección de fallas y reconocimiento del comportamiento del conductor.

En [21], se introdujo un método de control de modo deslizante difuso para minimizar el error del ángulo de dirección del vehículo, también se diseñó una ley de control de velocidad angular para que el error de trayectoria transversal sea cero. También se han presentado sistemas difusos para el diagnóstico, mantenimiento de motores y la predicción de posibles averías, en [22] se discutió cómo modelar la predicción de fallo mediante el uso de un enfoque difuso, mientras que en [23] se presentó una idea de arquitectura difusa profunda para la toma de decisiones en diagnóstico de fallos de maquinaria de los vehículos. La idea presentada en [24] utilizó el modelo de difuso Mamdani para sistema de IoT para estacionamiento de coches. Los sistemas difusos también se han utilizados en módulos de control para diversos motores eléctricos de vehículos autónomos [25].

En [26] se investigó la relación entre el estilo de conducción y el consumo de combustible, para lo cual se estimó el rendimiento de distintos conductores. En [27] se desarrolló un modelo en línea que describía los estilos de conducción mediante lógica difusa, con una precisión de 0.68. En [28] los autores introdujeron un método difuso para clasificar la conducción agresiva basado en el estilo del conductor. Los estilos de conducción se dividieron en cuatro categorías: por debajo de lo normal, normal, agresivo y muy agresivo. Por otra parte, en [29] se utilizaron los datos de la trayectoria del vehículo para crear dos modelos generalizados de estilo de conducción (agresivo y conservador).

Un análisis a detalle de estos trabajos nos permitió concluir que el modelo difuso Takagi-Sugeno y el sistema de inferencia difusa Mamdani son las dos categorías comunes de los sistemas de inferencia difusa. Sugeno supera a Mamdani en términos de eficiencia computacional, aunque Mamdani capta mejor la información humana. En este sentido, para este proyecto de investigación se optó por considerar la inferencia del tipo Mamdani, para abordar el reconocimiento del estado de conducción (seguro o riesgo). Lo cual consideramos como una aportación relevante entre la comunidad, para no hacer la tarea convencional de reconocer el estilo de conducción.

A.4. Desarrollo y evaluación de los sistemas para estimación del estado de conducción

1. Sistema de supervisión de la conducción basado en aprendizaje profundo y fusión de índices

Método propuesto

Para la estimación del estado de conducción se propusieron esquemas con funcionamiento en tiempo real. En la Figura A.4 se muestra el esquema de la propuesta inicial, la cual consiste en un árbol de inferencia conformada de tres modelos basados en aprendizaje profundo, así como un algoritmo para fusión de múltiples índices. Inicialmente el vídeo es capturado por una cámara estereó a color con alta resolución, la cual incluye un sensor de profundidad, un sensor inercial de 6-ejes, así como una unidad de procesamiento neuronal integrada con capacidad de inferencia de 4 tera operaciones por segundo. A continuación, se ejecutan los modelos de aprendizaje profundo en una unidad de procesamiento gráfico de alto rendimiento con capacidad de 32 tera operaciones por segundo. Como se mencionó previamente, el árbol de inferencia consta de tres modelos neuronales que se conectan de forma jerárquica en dos ramas. En el caso de la rama izquierda, se utilizan el model *face-detection-retail-0004* para detectar y recortar el rostro del conductor, así como el modelo *facial-landmarks-68-160×160* para detectar y recortar los ojos izquierdo, derecho y la boca del conductor. Estas tres últimas detecciones permiten calcular las estimaciones *EAR* (*Eye Aspect Ratio*) y *MOR* (*Mouth Opening Ratio*), respectivamente. La rama de inferencia de la derecha está formada por los modelos *face-detection-retail-0004* y *head-pose-estimation-adas-0001*, que realizan la detección y el recorte de la cara del conductor, posteriormente la estimación de los movimientos de mirar hacia abajo, girar a la derecha y girar a la izquierda del conductor. Además de la inferencia neuronal, la GPU embebida permite inferir el estado de conducción mediante un procedimiento de fusión multiíndice, que incorpora las salidas de los árboles de inferencia neuronal para el cálculo de los índices de estado de la boca, estado de los ojos y posición de la cabeza.

En este sistema se considera un algoritmo de fusión multiíndice para reconocer el estado de conducción, como fue mencionado con anterioridad se calcula a partir de los estados de la boca, los ojos y la postura de la cabeza; teniendo en cuenta el criterio de juicio de fatiga *perclos*, que se refiere a la proporción de tiempo de un estado particular dentro de un determinado tiempo.

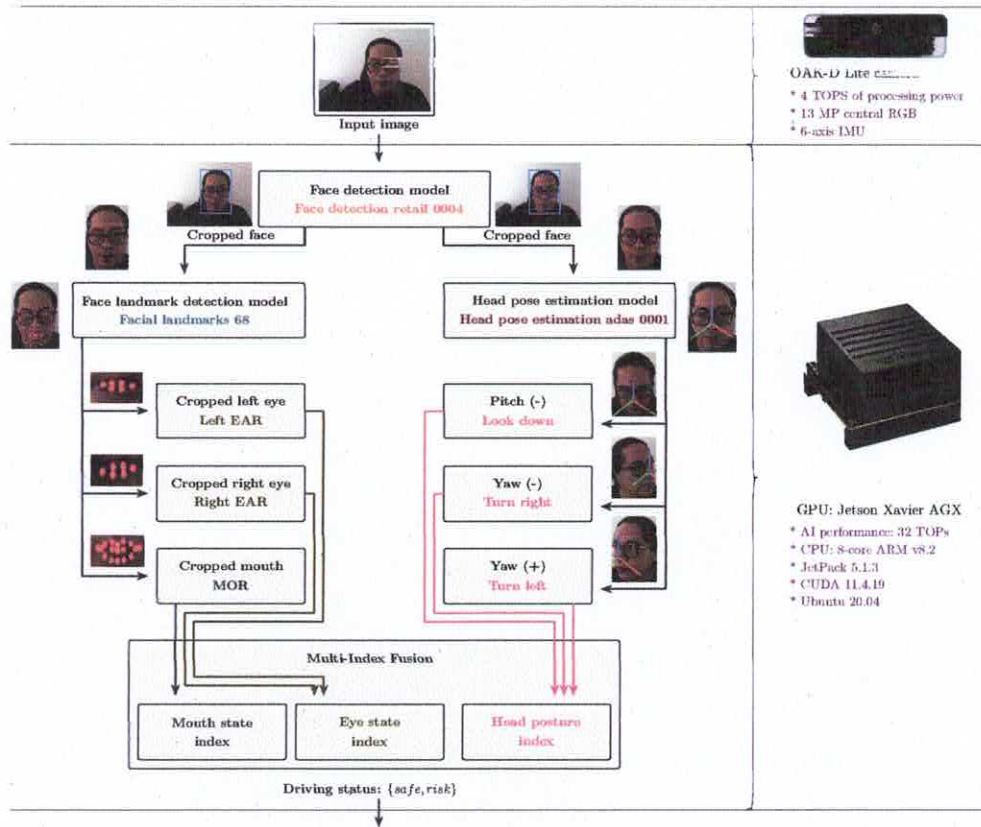


Figura A.4: Sistema basado en aprendizaje profundo y fusión de índices.

El índice *Mouth State Index* (*MSI*) es calculado considerando la métrica *MOR*, así como la siguiente expresión:

$$MSI = \frac{\tau_m}{T_m} \times 100\%, \quad (A.1)$$

donde τ_m es el número de cuadros con la boca abierta durante el tiempo de detección, y T_m es el número total de cuadros durante el tiempo de detección. El índice *Eyes State Index* (*ESI*) es calculado utilizando la métrica *EAR*, considerando la expresión siguiente:

$$ESI = \frac{\tau_e}{T_e} \times 100\%, \quad (A.2)$$

donde τ_e es el número de cuadros donde se reconocen los ojos cerrados, y T_e es el número total de cuadros durante el tiempo de detección. Finalmente, el índice *Head Posture Index* (*HPI*) es calculado mediante:

$$HPI = \frac{\tau_{hp}}{T_{hp}} \times 100\%, \quad (A.3)$$

donde τ_{hp} representa el número de fotogramas donde se detectan las poses de mirar hacia abajo, hacia la izquierda o la derecha, y T_{hp} es el número total de cuadros durante el tiempo de detección. Se

se propone normalizar el tiempo de detección de los índices A.1, A.2 y A.3 en un periodo de muestreo de 20 segundos. El algoritmo de la fusión multiíndice es formalizado en términos de los umbrales sugeridos en *percios* considerandos.

$$Driving\ status = \begin{cases} \text{unsafe} & MSI \geq 0.3 \wedge ESI \geq 0.5 \wedge HPI \geq 0.5 \\ \text{safe} & MSI < 0.3 \vee ESI < 0.5 \vee HPI < 0.5 \end{cases} \quad (A.4)$$

Estimación del desempeño

Para este experimento se consideraron los mismos vídeos que en la evaluación individual de los modelos neuronales; sin embargo, el sistema se evaluó como un esquema completo, considerando la integración de los tres modelos neuronales de aprendizaje profundo, así como el modelo de fusión multiíndice. La detección del estado de conducción se evaluó utilizando las mismas métricas. La Figura A.5 ilustra gráficamente los resultados cuantitativos obtenidos, destacando los valores mediano y el rango dinámico de estimaciones mínima y máxima, puntualizándose: $\tilde{\vartheta}_{Accuracy} = 0.936$, $0.918 \leq Accuracy \leq 0.948$; $\tilde{\vartheta}_{Recall} = 0.936$, $0.913 \leq Recall \leq 0.946$; $\tilde{\vartheta}_{Specificity} = 0.933$, $0.913 \leq Specificity \leq 0.948$; $\tilde{\vartheta}_{Precision} = 0.934$, $0.917 \leq Precision \leq 0.947$ y $\tilde{\vartheta}_{F1-Score} = 0.915$, $0.890 \leq F1-Score \leq 0.923$. Estos valores sugieren que el esquema propuesto tiene una eficacia superior al 91 % en la realización de la tarea de reconocimiento del estado de conducción, considerando dos estados posibles.




Figura A.5: Representación gráfica de los resultados cuantitativos.

2. Esquema híbrido de aprendizaje profundo e inferencia difusa para la supervisión de la conducción

Método propuesto

En la Figura A.6 se muestra el esquema de la segunda propuesta desarrollada, la cual consiste en un árbol de inferencia conformada de dos modelos basados en aprendizaje profundo, así como un módulo

de inferencia difusa. A diferencia del primer sistema, en este se omite el modelo neuronal *head-pose-estimation-adas-0001*, y se hace el cálculo de la pose del conductor mediante de los ángulos *pitch* y *yaw* provistos por el sensor de medición inercial de la cámara OAK-D Lite. Para hacer la inferencia del estado de conducción, se consideró un módulo difuso Mamdani del tipo-1. Este enfoque integra los resultados de los módulos de inferencia neuronal para la estimación de los índices de estado de la boca, estado de los ojos y posición de la cabeza, así como un conjunto de reglas del tipo sí-entonces para reconocer el estado de conducción.




Figura A.6: Sistema híbrido de aprendizaje profundo e inferencia difusa

El módulo difuso implica un sistema compuesto por múltiples entradas y una salida. En este sentido, las variables lingüísticas de entrada *Head Posture Index*, *Eye State Index* y *Mouth State Index* y salida *Driving Status* son modeladas como se muestra en la Figura A.7.

32




Figura A.7: Conjuntos difusos de tipo-1 para las entradas y salida.

En base a los conjuntos difusos considerados para las entradas y salidas, en esta investigación se propusieron las siguientes reglas:

1. If MouthStateIndex is min and EyesStateIndex is min and HeadPostureIndex is min
Then DrivingStatus is safe
2. If MouthStateIndex is max and EyesStateIndex is min and HeadPostureIndex is min
Then DrivingStatus is safe
3. If MouthStateIndex is min and EyesStateIndex is max and HeadPostureIndex is min
Then DrivingStatus is risk
4. If MouthStateIndex is max and EyesStateIndex is max and HeadPostureIndex is min
Then DrivingStatus is risk
5. If MouthStateIndex is min and EyesStateIndex is min and HeadPostureIndex is max
Then DrivingStatus is safe
6. If MouthStateIndex is max and EyesStateIndex is min and HeadPostureIndex is max
Then DrivingStatus is risk
7. If MouthStateIndex is min and EyesStateIndex is max and HeadPostureIndex is max
Then DrivingStatus is risk
8. If MouthStateIndex is max and EyesStateIndex is max and HeadPostureIndex is max
Then DrivingStatus is risk

Continuación se describe grosso modo las componentes de un sistema de inferencia difuso.

Sistema de Inferencia Difusa

Un sistema de inferencia difusa puede verse como una transformación de entradas a salidas deseadas que puede emplearse para acciones de control. Si n entradas $x_1 \in X_1, \dots, x_n \in X_n$ y una salida $y \in Y$ son considerados, esta transformación puede ser expresada como $y = f(\mathbf{x})$, donde $\mathbf{x} \equiv \{x_i\}_{i=1}^n$ [30]. Un sistema convencional de inferencia difusa de tipo 1 basado en reglas consta de cuatro componentes principales: base de reglas, fuzzificador, motor de inferencia difusa y defuzzificador. Para describir estos

componentes como un sistema, es necesario estandarizar el proceso de conceptualización y garantizar que el modelo resultante sea aplicable.

Base de reglas

Las reglas representan los elementos fundamentales de un sistema difuso: en ellas se transfieren el conocimiento y el razonamiento humanos, ya sea directamente de uno o varios expertos del dominio indirectamente a través de datos específicos del dominio. Un sistema difuso de entrada múltiple y salida única de tipo-1, basado en la metodología de inferencia de Mamdani emplea una estructura definida por la siguiente k -ésima regla:

$$\mathcal{R}^k : \text{IF } x_1 \text{ is } A_1^k \text{ and } \dots \text{ and } x_n \text{ is } A_n^k \text{ THEN } y \text{ is } \mathcal{C}^k, \quad (\text{A.5})$$

donde $A_1^k \in \{X_{1j}\}_{j=1}^{\mathcal{D}_1}, \dots, A_n^k \in \{X_{nj}\}_{j=1}^{\mathcal{D}_n}$, el término $\mathcal{D}_j$ se utiliza para referirse a los términos lingüísticos que modelan cada entrada i -entrada. Similarmente, $\mathcal{C}^k \in \{Y_j\}_{j=1}^{\mathcal{D}}$ delimita los términos lingüísticos que se emplearon para modelar la salida. El índice k se define como un índice acotado, que indica el número de reglas que deben tenerse en cuenta, es decir $1 \leq k \leq \mathcal{K}$.

FUZZIFICADOR

El fuzzificador es una función que transforma una entrada *crisp* en un conjunto difuso de tipo-1 $A_X \in \mathbf{X}$. La entrada es un vector que comprende n muestras proporcionadas por sensores, y puede denotarse como $(x_1, \dots, x_n)^T \in X_1 \times \dots \times X_n \equiv \mathbf{X}$. En el contexto de los sistemas difusos de tipo-1, la literatura sugiere el uso de fuzzificadores *singleton* y *no-singleton*. Sin embargo, para los fines de este estudio, se considera que el fuzzificador *no-singleton* es el más apropiado, este es expresado como $\mu_{X_i}(x_i|x'_i)$, para el cual $\mu_{X_i}(x_i|x'_i) = 1$ cuando $x_i = x'_i$ y $\mu_{X_i}(x_i|x'_i)$ decreciente desde la unidad, si x_i se aleja de x'_i .

Motor de inferencia difusa

El motor de inferencia es responsable de la combinación de reglas y de la generación de la transformación entre los conjuntos de tipo-1 de entrada y de salida [30]. Para lograr el objetivo mencionado, consideramos un conjunto de $\mathcal{K}$ reglas, cada una de las cuales tiene n entradas, x_n , así como una salida y . El proceso de transformación se formaliza de la siguiente manera:

$$\mathcal{R}^k : A_1^k \times \dots \times A_n^k \mapsto \mathcal{C}^k = \mathcal{A}^k \mapsto \mathcal{C}^k, \quad (\text{A.6})$$

donde $\mathcal{A}^k = A_1^k \times \dots \times A_n^k$. El grado de pertenencia para la k -ésima regla es cuantificada como $\mu_{\mathcal{R}^k}(\mathbf{x}, y) = \mu_{\mathcal{A}^k \mapsto \mathcal{C}^k}(\mathbf{x}, y)$, esta relación puede ser expandida de la siguiente forma:

$$\mu_{\mathcal{R}^k}(\mathbf{x}, y) = \left[\bigcap_{i=1}^n \mu_{A_i^k}(x_i) \right] \cap \mu_{\mathcal{C}^k}(y), \quad (\text{A.7})$$

Para esta expresión $\cap$ denota la intersección de los conjuntos difusos del tipo-1. Además, la entrada de un conjunto de n -dimensional reglas está definida por un conjunto difuso de tipo-1 $\mathcal{A}_i$. Para el cual la función de pertenencia es expresada como:

$$\mu_{\mathcal{A}_i}(\mathbf{x}) = \cap_{i=1}^n \mu_{\mathcal{X}_i}(x_i | \mathbf{x}'). \quad (\text{A.8})$$

Para establecer una conexión directa entre la entrada y la salida, es esencial reconocer que las reglas dictan qué conjuntos se activan en la salida. Esto se expresa formalmente de la siguiente manera:

$$\mu_{B^k}(y, \mathbf{x}') = \cup_{x \in X} [\mu_{\mathcal{A}_i}(\mathbf{x}) \cap \mu_{\mathcal{R}^k}(\mathbf{x}, y)], \quad (\text{A.9})$$

Considerando la sustitución de las expresiones (A.7) y (A.7) en (A.9) es posible establecer una relación entre las entradas y la salida de la forma:

$$\mu_{B^k}(y, \mathbf{x}') = \mathcal{F}^k(\mathbf{x}') \cap \mu_{C^k}(y), \quad (\text{A.10})$$

donde $\mu_{B^k}(y, \mathbf{x}')$ representa la función de pertenencia para un conjunto de salida de regla activada, mientras que $\mathcal{F}^k(\mathbf{x}')$ es el conjunto activado, esta relación es expandida de la siguiente forma:

$$\mathcal{F}^k(\mathbf{x}') = \cup_{i=1}^n \left[\cup_{x_i \in X_i} \left(\mu_{\mathcal{X}_i}(x_i | \mathbf{x}') \cap \mu_{\mathcal{F}_i^k}(x_i) \right) \right]. \quad (\text{A.11})$$

Defuzzificador

La última etapa del proceso de desarrollo de un sistema difuso es la defuzzificación. En esta etapa, uno o más conjuntos difusos se convierten en un único número real que puede ser usado como una acción de control. El defuzzificador centroide es el defuzzificador más antiguo y comunmente empleado en aplicaciones de sistemas difusos en el mundo real, a menudo resulta difícil y lento de calcular, debido a la necesidad de realizar integraciones en el dominio continuo. En este sentido, en el presente estudio se adoptará el método de defuzzificación *centro de conjuntos*. En este enfoque, cada conjunto de reglas consecuentes se sustituye por un único elemento situado en su centroide, con una amplitud igual al nivel de activación [30], por lo cual se requiere identificar los centros de los conjuntos activados en las salidas. La expresión para la defuzzificación con este método es expresada como:

$$y(\mathbf{x}') = \frac{\sum_{k=1}^K \delta^k f^k(\mathbf{x}')}{\sum_{k=1}^K f^k(\mathbf{x}')}, \quad (\text{A.12})$$

donde δ^k es el centroide del k -ésimo conjunto consecuente, mientras que $f^k(\mathbf{x}')$ denota el nivel de activación definido en la expresión (A.9).

913

Estimación del desempeño

La Tabla ofrece una visión general de los resultados cuantitativos, haciendo hincapié en los valores mediano, mínimo, máximo, así como la desviación estándar. Los resultados demuestran que el método propuesto es eficaz, con una tasa de éxito en el reconocimiento del estado de conducción superior al 92 % y una variabilidad mínima en los resultados.

Tabla A.5: Resultados cuantitativos del reconocimiento del estado de conducción.

Métrica	Mediana	Mínimo	Máximo	Desviación estándar
<i>Accuracy</i>	0.9306	0.9201	0.9385	0.0062
<i>Recall</i>	0.9292	0.9204	0.9398	0.0065
<i>Specificity</i>	0.9279	0.9205	0.9391	0.0068
<i>Precision</i>	0.9276	0.9201	0.9396	0.0063
<i>F1-Score</i>	0.9261	0.9199	0.9320	0.0045

Para proporcionar un contexto adicional y reforzar las conclusiones presentadas en las secciones anteriores, la Figura A.8 ofrece una representación gráfica de los datos visuales, que revela una distribución comparable de las métricas.




Figura A.8: Resultados gráficos para el reconocimiento del estado de conducción.

Es esencial destacar que la velocidad de procesamiento del sistema fue de aproximadamente 15 cuadros por segundo. Esto fue posible gracias a la capacidad de cálculo de la GPU Jetson Xavier AGX y a la incorporación de un coprocesador con capacidad de inferencia de redes neuronales dentro de la cámara OAK-D Lite. Cabe señalar, además, que los modelos neuronales muestran tiempos de inferencia significativamente reducidos durante la fase de prueba en comparación con la fase de entrenamiento, esta observación justifica el funcionamiento en tiempo real del sistema.

Handwritten signature and date: 2023

A.5. Conceptos matemáticos del sistema de Frenet y su uso en la generación de trayectoria:

El sistema de Frenet, también conocido como sistema curvilíneo, puede ser utilizado para facilitar la tarea de planificación de trayectorias en carreteras. Como se muestra en la Figura A.9, una carretera con forma irregular del mundo real representada en el espacio cartesiano se puede transformar en una carretera recta al utilizar sistema de Frenet. De este modo, las restricciones no lineales para conservación y cambio de carril, así como la evasión de colisiones, son convertidas en un problema de planificación de trayectorias con restricciones lineales [31]. Además, las restricciones cinemáticas originalmente acopladas se desacoplan como polinomios independientes en las dimensiones longitudinal y lateral.




Figura A.9: Esquema de conversión del sistema cartesiano al de Frenet.

Para generar trayectorias a lo largo de la forma del camino dado, el sistema de coordenadas de Frenet puede ser usado como una alternativa que se apegue mejor al desplazamiento vehicular [32]. En el sistema de coordenadas de Frenet, la trayectoria normal $d(t)$ y la trayectoria tangencial $s(t)$ se definen para la curva dada, como se muestra en la Figura A.10a. Sean $d(t)$ y $s(t)$ un patrón de compensación y un patrón de distancia, respectivamente. El patrón de desplazamiento corresponde a la cantidad de movimiento lateral dentro del carril de circulación. Por otro lado, el patrón de distancia corresponde al patrón de aceleración/desaceleración. Por lo tanto, la trayectoria del vehículo se formula en la siguiente expresión:

$$\vec{x}(s(t), d(t)) = \vec{r}(s(t)) + d(t)\vec{n}_r(s(t)) \quad (A.13)$$

En el uso práctico, se busca la trayectoria óptima mientras se ajustan los diversos tipos de condiciones terminales para cada patrón, como se muestra en la Figura A.10b.

Handwritten signature and date: 01/07




Figura A.10: Generación de trayectorias en el espacio de Frenet.

La trayectoria del vehículo es una combinación de un patrón de desplazamiento lateral $d(t)$ y un patrón de desplazamiento longitudinal $s(t)$. Ambos patrones se formulan generalmente como una función polinómica de 4^º o 5^º orden. Estos patrones de desplazamiento se definen de la siguiente forma:

$$d(t) = a_0 + a_1 t + a_2 t^2 + a_3 t^3 + a_4 t^4 + a_5 t^5 \quad (\text{A.14})$$

$$s(t) = b_0 + b_1 t + b_2 t^2 + b_3 t^3 + b_4 t^4 + b_5 t^5 \quad (\text{A.15})$$

donde las variables a_i y b_i son calculados a partir de las condiciones iniciales $[d_0, \dot{d}_0, \ddot{d}_0] / [s_0, \dot{s}_0, \ddot{s}_0]$ y condiciones terminales $[d_1, \dot{d}_1, \ddot{d}_1, \Delta T_d] / [s_1, \dot{s}_1, \ddot{s}_1, \Delta T_s]$ en un tiempo t_1 ($t_1 = t_0 + \Delta T_d$). El patrón de desplazamiento lateral $d(t)$ es definido usando una función polinómica de quinto para controlar la posición lateral con precisión. El patrón de distancia $s(t)$ se define utilizando funciones cuárticas o quínticas para mantener la velocidad y la distancia, respectivamente. Para controlar la velocidad de forma uniforme, el patrón de distancia se genera resolviendo una función de cuarto grado (haciendo que $b_5 = 0.0$). Por otro lado, para controlar la distancia con precisión hasta el vehículo que va delante, una función de quinto grado proporciona el patrón de distancia.

Para generar trayectorias sin colisiones para objetos estáticos y dinámicos, se generan trayectorias de varias condiciones terminales como candidatas según el carril. La trayectoria se define entre la condición inicial $[d_0, \dot{d}_0, \ddot{d}_0]$ en un tiempo t_0 y una condición terminal $[d_1, \dot{d}_1, \ddot{d}_1, \Delta T_d]$ en un tiempo t_1 . Teniendo en cuenta una conducción cómoda se debe minimizar la velocidad y la aceleración en dirección lateral, por lo tanto la condición terminal es $[d_1, \dot{d}_1, \ddot{d}_1, \Delta T_d] = [\Delta d, 0, 0, \Delta T_d]$. Se deben seleccionar varios valores de Δd y ΔT_d para generar varias trayectorias candidatas.

91 9

A.6. Estado del arte sobre métodos de toma de decisiones usados en el contexto del desplazamiento vehicular

La toma de decisiones es una parte vital de la tecnología de conducción autónoma. En función de la información proporcionada por el módulo de percepción del entorno, el módulo de toma de decisiones planifica los comportamientos de conducción adecuados y los envía al módulo de control de movimiento. Por lo tanto, la toma de decisiones suele considerarse el cerebro del vehículo autónomo (AV) y actúa como un puente entre la percepción del entorno y el control del movimiento [33]. El módulo de toma de decisiones influye mucho en las prestaciones de conducción de los vehículos autónomos, como la seguridad, la comodidad, la eficiencia y el consumo de energía. Se espera que los vehículos conducidos por humanos y los vehículos autónomos coexistan en las carreteras en las próximas décadas. La seguridad en la conducción no será el único requisito para los vehículos autónomos, y también es vital y vale la pena estudiar cómo interactuar con los vehículos conducidos por humanos en condiciones de tráfico complejas. Se espera que los vehículos autónomos se comporten de manera similar a los vehículos conducidos por humanos. Para ello, se deben tener en cuenta los comportamientos y las características de los conductores humanos en el diseño de la conducción autónoma. Si se considera que el comportamiento de conducción de los vehículos autónomos es similar al de los humanos, sería más fácil para los conductores humanos interactuar con los vehículos autónomos que los rodean y predecir su comportamiento, en particular en lo que respecta a la cooperación entre varios vehículos. De hecho, los distintos conductores presentan preferencias individuales en materia de seguridad, comodidad y eficiencia de viaje, lo que indica sus diferentes estilos de conducción. Por ejemplo, en términos de prevención de colisiones en situaciones de emergencia, los conductores agresivos pueden optar por una respuesta rápida de la dirección, mientras que los conductores tímidos pueden optar por accionar el pedal del freno. Además, los distintos pasajeros también pueden solicitar distintos estilos de conducción. Por ejemplo, si a bordo hay mujeres embarazadas, personas mayores y niños, se espera una experiencia de conducción más cómoda y segura. Por el contrario, para los viajeros diarios y los que tienen prisa, la eficiencia del viaje tiene una mayor prioridad durante sus viajes. Por lo tanto, desde la perspectiva del estilo de conducción, se espera que la toma de decisiones similar a la humana de los vehículos autónomos proporcione opciones personalizadas para pasajeros con diversos requisitos en materia de seguridad, comodidad y eficiencia de viaje.

Para lograr una toma de decisiones similar a la humana para los vehículos autónomos, se han estudiado diferentes metodologías, algoritmos y estrategias. En general, se pueden dividir en tres tipos: toma de decisiones similar a la humana basada en modelos, toma de decisiones similar a la humana basada en datos y toma de decisiones similar a la humana basada en la teoría de juegos [34].

Toma de decisiones basada en modelos

Algunos estudios han introducido elementos similares a los humanos, generalmente representados por características y estilos de conducción, en el desarrollo de algoritmos para la conducción autónoma [35, 36]. Para abordar el problema de la toma de decisiones, así como las interacciones con los vehículos circundantes, en [37] se propuso un enfoque del proceso de decisión de Markov (MDP) con mapas de potencial híbrido; mientras que en [38] se introdujo un enfoque de toma de decisiones robusto utilizando MDP parcialmente observable considerando mediciones inciertas, lo que permitió que los vehículos autónomos se movieran de manera segura y eficiente entre los peatones. Para abordar las incertidumbres de la toma de decisiones, los modelos probabilísticos se han utilizado como se presenta en [39, 40]. También se han considerado el método de toma de decisiones de criterios múltiples (MCDM) y el método de toma de decisiones de atributos múltiples (MADM) como alternativas eficaces para abordar entornos urbanos complejos y tomar decisiones razonables para los vehículos autónomos [41, 42]. En [43, 44] se consideraron entornos de conducción conectados, en los cuales los vehículos autónomos pudieron compartir sus estados de movimiento y pensamientos fácilmente, lo que resultó beneficioso para una toma de decisiones segura y eficiente. En [45, 46] los autores abordaron la toma de decisiones incorporando información de los carriles, así como la conexión entre vehículos autónomos conectados, a fin de proponer un enfoque de control centralizado. Para abordar la toma de decisiones de los CAV en las intersecciones, en [47, 48, 49] se estudió el concepto de sistema de gestión de tráfico centralizado, los autores propusieron un controlador centralizado para gestionar los CAV dentro del área controlada.

Toma de decisiones basada en datos

Con el desarrollo de algoritmos de aprendizaje automático, los métodos de toma de decisiones basados en aprendizaje basado en datos, han sobresalido técnicas como *Support Vector Machine* (SVM), *Clustered SVM* (CSVM), *Extreme Learning Machine* (ELM), *Kernel-based Extreme Learning Machine* (KELM), Aprendizaje por Reforzamiento (RL) y *Deep Neural Networks* (DNN) [50, 51, 52]. En [53], se aplicó un algoritmo SVM a la toma de decisiones automática con optimización de parámetros bayesianos, la propuesta abordó escenarios de tráfico complejos. En [54] se introdujo un sistema de toma de decisiones basado en redes neuronales profundas, éste se adaptaba a las condiciones reales de la carretera. En [55], combinando una red de autocodificadores profundos y el algoritmo XGBoost, se propuso un nuevo modelo de decisión de cambio de carril, el cual pudo tomar decisiones similares a las humanas para los vehículos autónomos. Dado que el reforzamiento de aprendizaje puede proporcionar muchos beneficios en la solución de problemas de decisión secuencial complejos e inciertos, en [56] se desarrolló un sistema

la toma de decisiones mediante la integración de MDP y RL. En [57], se utilizó un MDP estocástico para modelar la interacción entre un VA y el entorno, y luego se aplicó RL a la toma de decisiones basada en la función de recompensa de MDP. En comparación con las DNN y otros algoritmos de aprendizaje, el método RL no necesita un gran tamaño de conjunto de datos de conducción, en cambio, aprovecha un mecanismo de autoexploración que resuelve problemas de toma de decisiones secuenciales mediante la interacción con el entorno, esto fue demostrado en [58]. En [59], se evaluaron varios algoritmos de aprendizaje profundo en el marco de toma de decisiones. En [60], se estudió un algoritmo de toma de decisiones basado en aprendizaje profundo adaptativo y se diseñó un módulo de generación de trayectorias basado en optimización subyacente para mejorar la eficacia de la toma de decisiones. En resumen, los enfoques basados en aprendizaje se basan en los datos, por lo que su rendimiento se ve afectado por la calidad del conjunto de datos durante la fase de entrenamiento. Además, es difícil abordar la falla del algoritmo debido a la mala interpretabilidad del enfoque basado en datos.

Toma de decisiones basada en Teoría de Juegos

La Teoría de Juegos es otra forma eficaz de formular una toma de decisiones similar a la humana para vehículos autónomos con interacciones sociales. En [61] se propuso un modelo de cambio de carril basado en la teoría de juegos que pudo proporcionar un proceso similar al humano durante el cambio de carril de los vehículos autónomos. Basándose en la combinación de la teoría de juegos y el control predictivo, se propuso un método de ordenamiento de vehículos de múltiples carriles para decidir el tiempo óptimo y la aceleración del cambio de carril considerando la interacción mutua entre vehículos [62]. En [63], se utilizó el juego dinámico de un solo paso con información incompleta para abordar la toma de decisiones autónoma de cambio de carril para vehículos autónomos; la seguridad del vehículo, el rendimiento energético y la comodidad de los pasajeros fueron considerados en el proceso de cambio de carril. En [64], el enfoque de teoría de juegos se combinó con el reforzamiento de aprendizaje, mediante un algoritmo de aprendizaje de Nash-Q, para lograr una toma de decisiones similar a la humana para los vehículos autónomos. En [65], el método de Nash se aplicó a la toma de decisiones de múltiples vehículos autónomos en una glorieta, lo que permitió encontrar un buen equilibrio entre la seguridad de la conducción y la eficiencia del viaje para los vehículos autónomos. En [66], se propuso un modelo de cambio obligatorio de carril basado en la teoría de juegos (modelo AZHW) para el entorno tradicional y se amplió para el entorno conectado, este capturó de manera efectiva las decisiones de cambio de carril obligatorio con un alto grado de precisión. En [67], se diseñó un algoritmo de toma de decisiones para el control de vehículos autoconducidos en intersecciones de glorieteras, se consideró un enfoque de teoría de juegos. En [68], se aplicó un enfoque de juego cooperativo al problema de control de incorporación de rampas

de entrada de CAV, lo que redujo el consumo de combustible y el tiempo de viaje y mejoró aún más la comodidad del viaje. En general, los enfoques de teoría de juegos se pueden aplicar no sólo para gestionar la toma de decisiones de los vehículos autoconducidos sino también para simular los comportamientos interactivos de agentes inteligentes.

A.7. Desarrollo y evaluación del método propuesto para la selección de trayectorias

1. Sintonización fina de TOPSIS mediante transferencia de conocimiento a partir de diferentes estilos de conducción

Planificación y trazado de trayectorias

Esta propuesta combinó un algoritmo de planificación de trayectorias en el espacio de Frenet con el método de toma de decisiones TOPSIS. Para hacer una mejor selección entre las trayectorias generadas, se consideró una sintonización paramétrica fina, a partir de la imitación de la experiencia humana. En la Figura A.11 se muestra el esquema de trabajo propuesto, se indica en donde reside esta propuesta. Las trayectorias conectan los estados iniciales con los estados finales, éstos han sido definidos por el planificador de trayectorias, el cual traza la trayectoria desde el punto inicial al punto final, en función de parámetros específicos.




Figura A.11: Esquema de conversión del sistema cartesiano al de Frenet

La puntuación resultante de cada trayectoria se utiliza para determinar cual será la trayectoria que el vehículo debe seguir. El algoritmo planificador genera trayectorias a partir de los datos del entorno recopilados por el módulo de percepción. Las trayectorias están en el espacio de Frenet, éstas son curvas paramétricas $\gamma(t)$ formuladas a partir de:

$$\gamma(t) = (f(t)x + g(t)y + h(t)z) \quad (A.16)$$

19 2

donde $f(t)x$ representa el cambio de posición en x con respecto al tiempo t , $g(t)y$ representa el cambio de posición en y con respecto al tiempo t , $h(t)z$ es la función que expresa el cambio de posición en z con respecto al tiempo t . Los vectores tangente y normal trabajan como ejes para el nuevo sistema de referencia, y son calculados a partir de $\gamma(t)$ considerando:

$$T = \frac{\gamma'(t)}{\|\gamma'(t)\|_2}, \quad N = \frac{T'(t)}{\|T'(t)\|_2} \quad (A.17)$$

$\gamma'(t)$ y $T'(t)$ son las primeras derivadas, $\|\gamma'(t)\|_2$ y $\|T'(t)\|_2$ son las normas euclidianas. El vector T es el eje para el movimiento longitudinal y N es el eje para el movimiento lateral. El polinomio de quinto orden genera la trayectoria que conecta de manera global el estado inicial $S_i = [\psi_0^1, \psi_0^2, \dots, \psi_0^n]$; con respecto al estado final $S_t = [\psi_f^1, \psi_f^2, \dots, \psi_f^n]$. La trayectoria conjuga un cierto número de movimientos laterales $d(t)$ y longitudinales $s(t)$ y se define mediante las siguientes expresiones:

$$d(t) = d_0 + d_1 t + d_2 t^2 + d_3 t^3 + d_4 t^4 + d_5 t^5 \quad (A.18)$$

$$s(t) = s_0 + s_1 t + s_2 t^2 + s_3 t^3 + s_4 t^4 + s_5 t^5 \quad (A.19)$$

los coeficientes $[d_0, \dots, d_5]$ y $[s_0, \dots, s_5]$ son determinados a partir de la geometría del camino. Las velocidades para los desplazamientos d y s son derivadas a partir de la primera derivada de las expresiones A.18 y A.19, mientras que las aceleraciones son determinadas a partir de la segunda derivada. Al usar diferentes conjuntos de S_i y S_t se producen diferentes trayectorias a través del algoritmo polinomial.

Para el cálculo del ángulo de dirección se asume una velocidad constante [69], considerando el ángulo de trayectoria real del vehículo ρ , el ángulo deseado σ , el ángulo direccional V_f , e una medida de distancia desde el eje delantero hasta la trayectoria y L la distancia entre los ejes. El primer paso es cancelar el error entre la trayectoria real y la deseada, mediante la siguiente expresión:

$$\sigma(t) = \rho(t) \quad (A.20)$$

Posteriormente, el error de cruce de carril se elimina encontrando el punto más cercano entre la trayectoria trazada y el centro del eje delantero del vehículo, denotado por $e(t)$:

$$\sigma(t) = \tan^{-1}\left(\frac{K e(t)}{V_f(t)}\right) \quad (A.21)$$

donde K es la ganancia, σ es el ángulo correcto del vehículo, este ángulo debe limitarse a los ángulos máximos de giro; es decir, $\sigma(t) \in [\sigma_{min}, \sigma_{max}]$. Esto nos lleva a la siguiente expresión:

$$\sigma(t) = \rho(t) + \tan^{-1}\left(\frac{K e(t)}{V_f(t)}\right), \quad \sigma(t) \in [\sigma_{min}, \sigma_{max}] \quad (A.22)$$

La ganancia k_s puede ser agregada para suavizar el control y asegurar que el denominador no sea cero, tal como se formaliza en la siguiente expresión:

$$\sigma(t) = \rho(t) + \tan^{-1}\left(\frac{Ke(t)}{k_s + V_f(t)}\right) \quad (A.23)$$

El planificador de trayectorias genera un arreglo δ con columnas $[d, s, \alpha, v, a]$; de manera específica, d contiene punto en el eje lateral, s contiene puntos en el eje longitudinal, α es el ángulo de dirección en cada punto calculado en relación al estado inicial, al estado objetivo y la desviación lateral, v es la velocidad y a es la aceleración. Debido a que los algoritmos polinomiales generan un conjunto de valores para cada tiempo t , el arreglo δ contiene un número de puntos que forman una única trayectoria, dependiendo de la situación cada trayectoria puede contener un número entre 10 y 50 puntos individuales, y dependiendo de la situación se pueden generar de 1 a 20 trayectorias por carril de la vía.

Selección de trayectorias

El método toma de decisiones multi criterio considerado para la tarea de selección de la trayectoria óptima fue TOPSIS. Ya que esta técnica implica un costo computacional bajo y es fácilmente escalable para tener en cuenta nuevos criterios con modificaciones menores. Grosso modo se selecciona la trayectoria con el puntaje más alto y luego se usa como referencia para el vehículo a seguir, el proceso de generar nuevas trayectorias y elegir la adecuada se repite cada vez que el módulo de percepción del vehículo actualiza los estados inicial y final.

Sintonización fina para la selección de trayectorias

TOPSIS considera dos vectores para ajustar la preferencia en el proceso de toma de decisiones. El vector W sirve como indicador de la importancia de cada criterio para la decisión global, y puede tomar cualquier valor real, para este trabajo los valores fueron acotados entre $[1, 5]$. Por otra parte, el vector I indica el deseo de aumentar o disminuir el valor de cada criterio, esto se expresa con los símbolos "+" y "-" respectivamente, por ejemplo si se desea reducir la velocidad del vehículo, el valor en el vector I se ajusta a "-" para ese criterio. En primera instancia sólo se consideraron para el ajuste fino los criterios $[\alpha, v, a]$, si se considera que cada criterio podría tener valores en el vector W en el rango de $[1, 5]$ y tomar cualquiera de las dos opciones en el vector I . Para expresar el total de las combinaciones posibles, se pueden considerar:

$$5 * 5 * 5 = 5^3 = 125 \quad (A.24)$$

como las combinaciones disponibles del vector W . Mientras que para el vector I se tienen las siguientes combinaciones:

$$2 * 2 * 2 = 2^3 = 8 \quad (A.25)$$

Como estos vectores trabajan en conjunto, el número total de combinaciones es 1000 para los tres criterios considerados en TOPSIS. Cada par de vectores determina el comportamiento del vehículo en el curso de acción óptimo en diferentes condiciones. Para identificar la solución óptima, utilizamos el *Método de Optimización Bayesiano* para ajustar los vectores de impacto y los pesos requeridos en TOPSIS; la función objetivo se definió para maximizar el puntaje promedio. Esto permitió que el algoritmo seleccionara la trayectoria más apropiada en condiciones específicas. Si bien cada simulación tomó entre 10 y 15 minutos, dependiendo de las condiciones, el proceso de identificación de la combinación óptima de vectores fue relativamente corto. Como se dijo anteriormente, el número de combinaciones fue relativamente limitado. A medida que aumenta el número de criterios, el número de opciones posibles aumenta exponencialmente, como lo demuestra la siguiente expresión:

$$5^n * 2^n = (5 * 2)^n = 10^n \quad (\text{A.26})$$

Transferencia de experiencia

Al considerar el vector de criterios $[\alpha, \nu, a, R_{vd}, P, B_d, L_C]$ el número de alternativas es de 10^7 . El proceso de ajuste fino del número de combinaciones antes mencionado requeriría una cantidad considerable de tiempo y recursos. Esto es particularmente evidente cuando se consideran las ventajas del método considerado de toma de decisiones basado en multi criterios. Para solventar esta problemática, en este proyecto se consideró utilizar la variante Fuzzy-TOPSIS, la cual considera los vectores W e I adaptados para incorporar la experiencia humana como un medio de inferencia. Para ello se aplicó una encuesta a 50 conductores, con un rango de 18 a 60 años, así como con diferentes niveles de experiencia al volante. Los datos recopilados se utilizaron para ajustar los valores de cada criterio, en un rango de $[1, 5]$, para cada parámetro se consideraron los indicadores "+" y "-" para indicar un incremento o decremento en la preferencia del conductor encuestado. A partir de esta información se obtuvieron los datos de la Figura A.12, la cual muestra la distribución de los valores obtenidos de las encuestas.




Figura A.12: Valores obtenidos por criterio a partir de la encuesta.

La respuesta mediana para el criterio α es 3, lo que indica preferencias neutrales a ligeramente positivas, con un rango intercuartil de 2 a 4. Un valor atípico en 5 muestra que algunas personas tienen una preferencia extremadamente alta. El criterio ν sigue el mismo patrón, con una mediana de 3, un rango intercuartil de 2 a 4 y un valor atípico en 5. Para el criterio a , la mediana es 3 y el rango intercuartil es de 2 a 4, con un valor atípico en 5 que indica fuertes preferencias para algunos. El criterio R_{vd} tiene una mediana de 3 y un rango intercuartil de 2 a 4, pero los valores atípicos en 0 y 1 sugieren cierta desaprobación fuerte. El criterio P muestra una mediana de 3 y un rango intercuartil de 2 a 4, con un valor atípico en 1 que indica baja preferencia por algunos. El criterio B_d también tiene una mediana de 3, un rango intercuartil de 2 a 4 y un valor atípico en 5. Por último, el criterio L_C tiene una mediana de 3, un rango intercuartil de 2 a 4 y un valor atípico en 5. Estos hallazgos sugieren tres estilos de conducción distintos: moderado (mediana de 3, rango intercuartil de 2 a 4), conservador (valores atípicos bajos en 0 y 1) y agresivo (valores atípicos altos en 5), lo que indica un espectro de enfoques de conducción conservadores a agresivos. La existencia de estos tres estilos de conducción permite una comprensión más profunda de las necesidades y preferencias de los conductores, lo que puede resultar útil para el diseño de políticas de transporte, campañas de seguridad vial y para los fabricantes de automóviles que buscan personalizar sus productos para diferentes segmentos del mercado. La identificación de estos estilos sugiere que los enfoques unificados pueden no ser efectivos y que las estrategias diferenciadas pueden ser más exitosas para atender a diversos grupos de conductores. En conclusión, el reconocimiento de la diversidad en las preferencias de conducción puede facilitar la formulación de decisiones más informadas y adaptadas a las necesidades específicas de cada grupo de conductores. Los vectores obtenidos para cada estilo de conducción se resumen en la Tabla A.6.

Tabla A.6: Valores de los vectores W e I para cada estilo de conducción

Estilo conducción	Vector	α	ν	a	R_{vd}	P	B_d	L_C
Moderado	W	2	4	4	3	5	5	4
	I	-	-	-	+	-	+	-
Conservador	W	2	3	2	3	5	4	3
	I	-	+	-	+	-	+	-
Agresivo	W	3	5	4	3	3	3	3
	I	+	+	+	+	-	-	+

Resultados experimentales

Para los experimentos se diseñó un escenario de conducción, el cual cuenta de diferentes segmentos rectos y curvos intercalados a lo largo del camino. El camino tiene una longitud de 1.75 km y consta de cuatro carriles, cada uno con un ancho de 2.2 m. El escenario no contempla intersecciones o cruces

de ningún tipo. Al modelo sólo se le proporciona la curva de referencia del camino, la cual describe la geometría del mismo, y el ancho del carril. En la Figura A.13 se puede apreciar el escenario en el cual se llevaron a cabo los experimentos. Para el vehículo autoconducido se consideró una longitud de 4.5 m y un ancho de 1.9 m.




Figura A.13: Escenario diseñado para los experimentos.

Para cuantificar el desempeño del método propuesto, se tomaron como referencia, las métricas *Efficiency*, *Safety*, *Comfort* y *LCFQI* propuestas en [70].

Efficiency: Denota la velocidad longitudinal promedio del vehículo autónomo y el resto de los vehículos en el escenario, a través de esta métrica se puede evaluar la eficiencia del vehículo controlado y la velocidad relativa del todo el flujo de tráfico con las funciones:

$$\bar{v}_{AVs} = \frac{\sum_{i=1}^n \sum_{j=1}^m v_{AV_{ij}}}{N} \quad (\text{A.27})$$

$$\bar{v}_S = \frac{\sum_{i=1}^n \sum_{j=1}^m v_{ij}}{N_{all}} \quad (\text{A.28})$$

donde $v_{AV_{ij}}$ representa la velocidad longitudinal de la trayectoria i en el tiempo j , v_{ij} es la velocidad longitudinal del vehículo i en el tiempo j , N es la cantidad total de trayectorias, contemplando que cada una cuenta con una velocidad diferente para cada instante de tiempo, N_{all} indica el número total de las velocidades para todos los vehículos en todos los instantes de tiempo.

Safety: Debido a la presencia de varios obstáculos en el escenario, se definió un porcentaje de colisión como la probabilidad de que el vehículo colisione en cada proceso de generación selección de trayectorias, esta probabilidad se expresa en la siguiente expresión:

$$P_{collision} = \frac{N_{collision}}{N_{NCV}} \quad (\text{A.29})$$

donde $N_{collision}$ es el número de trayectorias con colisiones en cada proceso, N_{NCV} representa la cantidad de obstáculos con los que se tiene una interacción.

Handwritten signature and date: 21-9

Comfort: Para evaluar el confort se contempló medir los cambios de aceleración en cada trayectoria seleccionada, contemplando que un cambio de aceleración se podría denotar en el siguiente rango $(-\infty, -4.5 \text{ m/s}^2)$

LCFQI: Esta métrica se compone por dos partes principales: Frecuencia de Cambio de Carril (LCF) que mide la frecuencia con la que un vehículo cambia de carril, basándose en el número total de cambios de carril; Calidad de Cambio de Carril (LCQ), la cual evalúa la suavidad, seguridad y adecuación de cada cambio de carril, con subcomponentes que incluyen Suavidad (S), que mide la calidad de la transición; Seguridad (S_a), que evalúa el cumplimiento de las normas de seguridad; y Adecuación (A_p), que mide la necesidad y sensibilidad de los cambios de carril.

$$LCFQI = (\alpha \cdot LCF) + (\beta \cdot LCQ) \quad (A.30)$$

$$LCQ = w_s \cdot S + w_{sa} \cdot S_a + w_{ap} \cdot A_p \quad (A.31)$$

donde α y β son factores de ponderación que determinan la importancia relativa de la frecuencia y la calidad. S denota el componente de suavidad, S_a denota el componente de seguridad, A_p representa el componente de adecuación, w_s , w_{sa} y w_{ap} son factores de ponderación para cada subcomponente, respectivamente.

A. Presencia de objetos estáticos

Para el primer experimento se consideró la presencia de objetos estáticos, los cuales representaban barreras de 2 m colocadas aleatoriamente en los carriles, así como 4 vehículos no controlados dispuestos en el circuito. La Figura A.14 presenta de manera gráfica los resultados cuantitativos normalizados de la evaluación de TOPSIS con parámetros sintonizados a partir de la optimización bayesiana, así como los obtenidos a partir de la experiencia humana. Para ambos casos se observa que la conducción conservadora tienen los resultados más altos en términos de eficiencia, seguridad y comodidad; así como una menor frecuencia de cambio de carril. Por su parte, la conducción agresiva al incrementar considerablemente los cambios de carril, hace que las tres primeras métricas tienden a reducir. Aunado a lo anterior, el contraste entre una técnica formalizada matemáticamente con respecto a una técnica con tintes más heurísticos no presenta una diferencia significativa en los resultados obtenidos.




Figura A.14: Resultados cuantitativos obtenidos por TOPSIS, considerando objetos estáticos.

B. Presencia de objetos dinámicos

Para el segundo experimento, se configuró para que los 4 vehículos no controlados siguieran trayectorias aleatorias con el propósito de obstaculizar la circulación del vehículo controlado. En la Figura A.15 se resumen visualmente los resultados cuantitativos obtenidos, como se observa ambas técnicas de sintonización paramétrica hicieron que la calidad del resultado de TOPSIS se mermara de manera evidente. Lo cual es natural ante la presencia de objetos dinámicos que obstaculizan el desplazamiento del vehículo autoconducido, ya que para los tres tipos de conducción se requirió incrementar la frecuencia de cambio de carril.




Figura A.15: Resultados cuantitativos obtenidos por TOPSIS, considerando objetos dinámicos.

A partir de ambos experimentos se puede concluir que el estilo conservador mostró el mejor equilibrio, manteniendo un buen nivel de eficiencia y seguridad sin sacrificar la comodidad ni realizar una gran cantidad de maniobras. Sin embargo, éste requiere un mayor tiempo de ejecución que el estilo de conducción moderada. Por consiguiente, si el tiempo se considera como una métrica con mayor ponderación, entonces la conducción moderada sería la mejor alternativa, ya que ésta no presenta variación significativa en términos cuantitativos.

49

La búsqueda de los vectores mediante técnicas de ajuste fino requieren una cantidad considerable de tiempo y recursos, por lo que estos resultados apoyan la idea de utilizar otro tipo de técnicas para ajustar los parámetros, como la transferencia de conocimiento, basada en pesos para agregar experiencia humana a los métodos de toma de decisiones. Donde pueden ser una alternativa a otro tipo de técnicas de toma de decisiones. Para trabajos futuros, se considera mejorar los mecanismos de transferencia de experiencia para obtener más información de los conductores y definir con más precisión los estilos de conducción observados, además, se propone experimentar con el *Fuzzy TOPSIS* con el fin de adaptar las funciones de membresía a través de la experiencia de los conductores para tener una conducción más suave y con menos problemas al interactuar con conductores humanos.

2. Método de toma de decisiones multiatributo basado en TOPSIS para la selección de trayectorias en un entorno con muchos obstáculos

La Figura A.16 ilustra el enfoque propuesto empleado en esta investigación, en la cual se indican las interrelaciones entre los distintos módulos que componen colectivamente el sistema de control del vehículo.

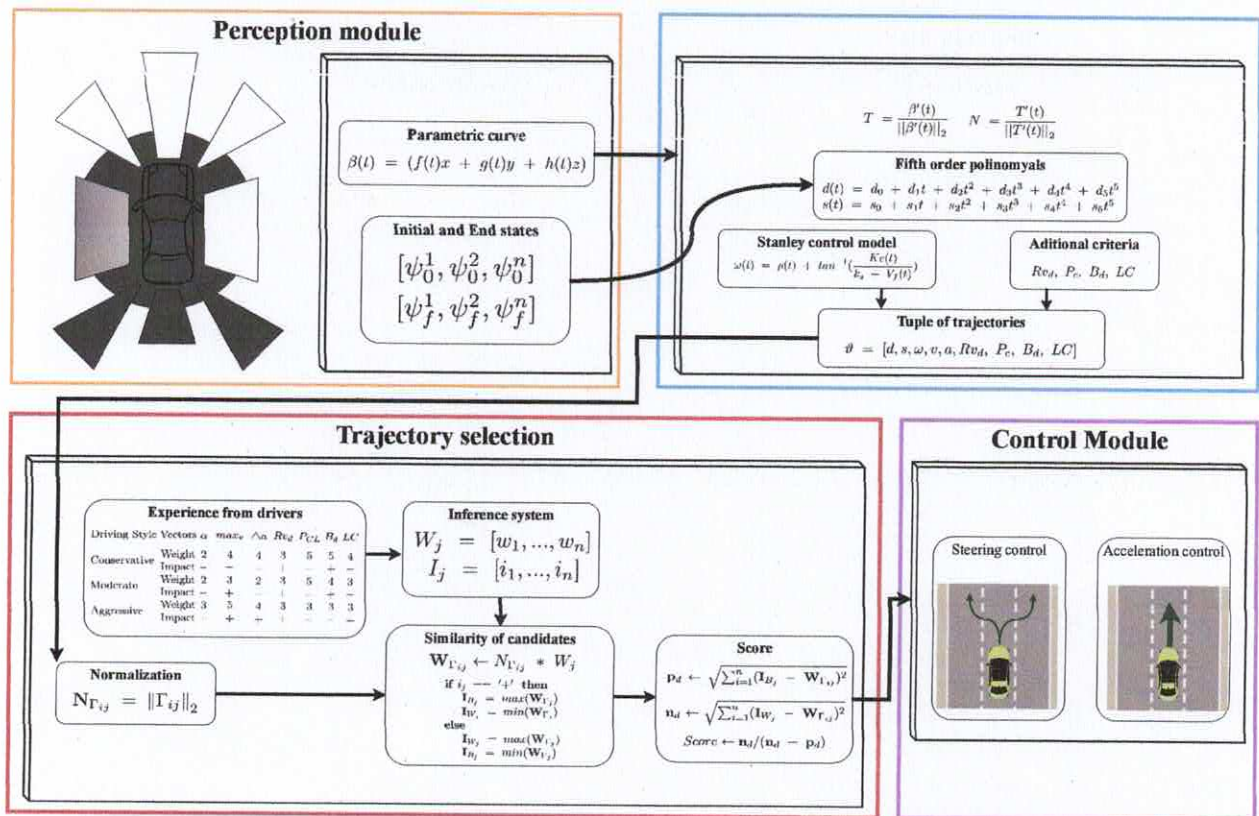


Figura A.16: Método propuesto.

Módulo de percepción En este módulo se obtiene información del entorno, mediante diferentes sensores como: cámaras RGB, sensor LiDAR, sensores ultrasonidos, sensores infrarrojos, sistemas de visión por computadora por mencionar algunos. En este caso nos interesa recopilar información sobre la posición de otros vehículos, las condiciones del camino, señalamientos y la geometría del camino. Esta última corresponde a la curva paramétrica $\gamma(t)$, donde $f(t)x$ representa el cambio de posición en x respecto al tiempo t , $g(t)y$ representa el cambio en y en un tiempo t y $h(t)z$ es la función que expresa el cambio en z en t . Además de esto, también se recopila información del propio vehículo, como la velocidad, aceleración y ángulo de la dirección. Todos estos datos son utilizados como estados iniciales $[\psi_0^1, \psi_0^2, \dots, \psi_0^n]$ y finales $[\psi_f^1, \psi_f^2, \dots, \psi_f^n]$, los cuales sirven para crear los puntos de las trayectorias que el vehículo puede tomar.

Módulo de planificación de trayectorias Una vez que se obtuvo la curva paramétrica y los estados iniciales y finales, es necesario construir un sistema de referencia móvil que elimine la discretización del entorno, en este caso se utilizó el espacio de Frenet tomando como ejes los vectores tangente T y normal principal N , este sistema de referencia se traslada a lo largo de toda la curva paramétrica lo cual permitió ubicar con mayor precisión las entidades presentes en el camino. En este nuevo espacio se generaron las trayectorias mediante la variación de los coeficientes de los polinomios de quinto orden, con los cuales se describió el movimiento en los ejes lateral s y longitudinal d . Con estos polinomios y sus respectivas derivadas fue posible obtener la posición, velocidad y aceleración del vehículo en cada uno de los puntos de la trayectoria. Para obtener la corrección del ángulo de giro se utilizó el modelo de control de Stanley, con toda esta información se obtuvo a la salida de este módulo un conjunto de trayectorias con los valores de cada variable para todos los puntos que conforman la trayectoria.

Módulo de selección de trayectorias Al generar más de una trayectoria, fue necesario realizar una selección de entre las opciones generadas, en este caso se decidió utilizar un método de toma de decisiones para seleccionar la adecuada. Este método requirió realizar una transformación de la tupla de trayectorias, la cual se trasladó al dominio difuso mediante una normalización de todos los valores dentro del conjunto Γ_{ij} . La técnica TOPSIS cuenta con un sistema de inferencia compuesto de los vectores W e I mediante los cuales se determinó el peso e impacto de cada uno de los criterios utilizados para evaluar las trayectorias. Con estos vectores fue posible estimar una solución ideal y a partir de esta, evaluar cual de las trayectorias generadas se encontraba más cerca de los valores ideales I_{B_j} y I_{W_j} . Finalmente se obtuvo un puntaje o *Score* mediante el cálculo de la distancia euclidiana entre las trayectorias y los valores ideales.

Módulo de control del vehículo Finalmente una vez que se seleccionó la trayectoria con el *Score* más alto, fue necesario que el vehículo se apegara a esta. Para lograr esto se implementó un modelo de control, en este caso el modelo de control *Pure Pursuit* o modelo de *Stanley* el cual realizó los ajustes de velocidad y ángulo de dirección a partir de una señal de referencia, que en este caso fue la trayectoria seleccionada en el módulo anterior.

Formalización matemática de los módulos propuestos

Módulo de Planificación de Trayectorias

El algoritmo de planificación de trayectorias produce trayectorias basadas en los datos del módulo de detección ambiental, que incorpora todos los sensores y técnicas utilizados por el sistema para conocer el entorno circundante. El espacio de Frenet se construye inicialmente sobre una curva paramétrica $\beta(t)$, que describe la trayectoria de acuerdo con la expresión:

$$\beta(t) = (f(t)x + g(t)y + h(t)z) \quad (A.32)$$

donde $\beta(t)$ representa la expresión de la curva paramétrica, $f(t)x$ denota el cambio en la posición en x con respecto al tiempo t . De manera análoga, $g(t)y$ es el cambio en y en el tiempo t , mientras $h(t)z$ es la función que expresa el cambio en z en t . En el nuevo sistema de referencia, los vectores tangente T y normal N representan a los ejes, considerando su origen en $\beta(t)$. La relación entre estos vectores y el nuevo sistema de referencia es dada por las siguientes expresiones:

$$T = \frac{\beta'(t)}{\|\beta'(t)\|_2}, \quad N = \frac{T'(t)}{\|T'(t)\|_2} \quad (A.33)$$

donde $\beta'(t)$ and $T'(t)$ son las primeras derivadas, $\|\beta'(t)\|_2$ y $\|T'(t)\|_2$ son las normas Euclidianas. Una ventaja significativa que ofrece el espacio de Frenet es la descripción precisa del movimiento de las entidades a lo largo de la geometría de la carretera. Esto elimina la necesidad de discretización, lo que proporciona una ventaja significativa en términos de la precisión con la que se pueden estimar los obstáculos y la posición del vehículo. En espacio de referencia, se puede aplicar un polinomio de quinto orden como el de la expresión (A.34) para generar las diferentes trayectorias.

$$Y(t) = a_0 + a_1t + a_2t^2 + a_3t^3 + a_4t^4 + a_5t^5 \quad (A.34)$$

La función $Y(t)$ describe la trayectoria, los coeficientes a_0 , a_1 , a_2 , a_3 , a_4 and a_5 son calculados a partir de las características de la trayectoria. La velocidad es obtenida a partir de la primera derivada de la expresión de tercer orden (A.35). La aceleración se obtiene posteriormente a través de la segunda derivada, dada por (A.36).

$$Y'(t) = v(t) = a_1 + 2a_2t + 3a_3t^2 + 4a_4t^3 + 5a_5t^4 \quad (A.35)$$

$$Y''(t) = \alpha(t) = 2a_2 + 6a_3t + 12a_4t^2 + 20a_5t^3 \quad (A.36)$$

Los coeficientes de las ecuaciones anteriores se pueden determinar a partir de la siguiente matriz:

$$\begin{bmatrix} 1 & t_0 & t_0^2 & t_0^3 & t_0^4 & t_0^5 \\ 0 & 1 & 2t_0 & 3t_0^2 & 4t_0^3 & 5t_0^4 \\ 0 & 0 & 2 & 6t_0 & 12t_0^2 & 20t_0^3 \\ 0 & t_f & t_f^2 & t_f^3 & t_f^4 & t_f^5 \\ 0 & 1 & 2t_f & 3t_f^2 & 4t_f^3 & 5t_f^4 \\ 0 & 0 & 2 & 6t_f & 12t_f^2 & 20t_f^3 \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \\ a_2 \\ a_3 \\ a_4 \\ a_5 \end{bmatrix} = \begin{bmatrix} Y_0 \\ V_0 \\ A_0 \\ Y_f \\ V_f \\ A_f \end{bmatrix} \quad (A.37)$$

Además de los datos derivados de los polinomios de quinto orden, es de gran importancia conocer el ángulo de dirección ω del vehículo sujeto. Mediante el análisis de las trayectorias generadas, es posible determinar el ángulo necesario, asegurando así que el vehículo se mantenga en la trayectoria deseada. Para lograr el objetivo antes mencionado, fue necesario considerar cada trayectoria como un punto de referencia con un ángulo deseado de ρ , y posteriormente aplicar las siguientes ecuaciones del módulo de control Stanley para rectificar el ángulo de dirección del vehículo.

$$\omega(t) = \rho(t) \quad (A.38)$$

El error de cruce de vía se corrige posteriormente mediante la identificación del punto de aproximación más cercano entre la trayectoria trazada y el centro del eje delantero del vehículo (denotado por $e(t)$). Este ajuste da lugar a la siguiente expresión:

$$\omega(t) = \tan^{-1} \left(\frac{Ke(t)}{V_f(t)} \right) \quad (A.39)$$

donde K es la ganancia y ω es el ángulo corregido del vehículo. Este ángulo debe estar delimitado por el ángulo máximo de giro, es decir $\omega(t) \in [\omega_{min}, \omega_{max}]$. Bajo esta restricción se puede formalizar la expresión:

$$\omega(t) = \rho(t) + \tan^{-1} \left(\frac{Ke(t)}{V_f(t)} \right), \omega(t) \in [\omega_{min}, \omega_{max}] \quad (A.40)$$

Una ventaja adicional implica la introducción de la ganancia k_s para facilitar el control, así como para garantizar que el denominador no sea igual a cero, es decir:

$$\omega(t) = \rho(t) + \tan^{-1} \left(\frac{Ke(t)}{k_s + V_f(t)} \right) \quad (A.41)$$

En resumen, el proceso de obtención de las trayectorias se puede expresar en el Algoritmo 1, el cual produce un conjunto de trayectorias que posteriormente se evalúan mediante un método de toma de decisiones multicriterio para determinar la solución óptima.

Algorithm 1 Path planning using the Frenet Reference Frame**Require:** $\varpi(t)$ parametric curve, $[\psi_0^1, \psi_0^2, \psi_0^n]$ initial states, $[\psi_f^1, \psi_f^2, \psi_f^n]$ target states.**Ensure:** $\delta = [d, s, \omega, v, a]$

▷ Matrix of the generated trajectory points

1: **Reference Frame Creation**

$$T \leftarrow \frac{\beta'(t)}{\|\beta'(t)\|_2}$$

▷ Tangent vector used as the longitudinal axis

$$N \leftarrow \frac{\gamma'(t)}{\|\gamma'(t)\|_2}$$

▷ Principal Normal vector used as the lateral axis

2: **Polynomial Computation**

$$d(t) = d_0 + d_1 t + d_2 t^2 + d_3 t^3 + d_4 t^4 + d_5 t^5$$

▷ Lateral displacement

$$s(t) = s_0 + s_1 t + s_2 t^2 + s_3 t^3 + s_4 t^4 + s_5 t^5$$

▷ Longitudinal displacement

3: **Kinematic Computation**

$$v \leftarrow s'(t)$$

▷ Velocity

$$a \leftarrow s''(t)$$

▷ Acceleration

$$\omega$$

▷ Steering angle

4: **Data Aggregation**

$$\vartheta = [d, s, \omega, v, a]$$

▷ Aggregation of the data into a matrix for each trajectory

Módulo de Selección de Trayectorias

Para evaluar las trayectorias generadas se empleó la Técnica de Ordenamiento Preferencial por Similitud con la Solución Ideal (TOPSIS, por sus siglas en inglés). Esto implicó determinar una solución ideal, ya sea como mejor ideal o peor ideal, y ajustarla en función de la experiencia del conductor humano. Este método permitió integrar la experiencia humana en el proceso de toma de decisiones. Esto requirió el uso de una matriz, designada como Γ , que abarcaba los candidatos, el vector de peso, denotado como W , y el vector de impacto I . El vector de peso, $W = [w_1, \dots, w_n]$, comprendía los pesos asociados con cada columna de la matriz Γ . Estos pesos podían asumir cualquier valor entre $[1, \infty]$. El vector de impacto, $I = [i_1, \dots, i_n]$, representaba el impacto, indicando la preferencia del algoritmo TOPSIS para aumentar o disminuir los valores de las respectivas columnas. La etapa inicial del algoritmo TOPSIS implicó la normalización de la matriz Γ , considerando:

$$N_{\Gamma} = \|\Gamma_{ij}\|_2 = \frac{\Gamma_{ij}}{\sqrt{\sum_{i=1}^n \sum_{j=1}^n (x_{ij})^2}} \quad (\text{A.42})$$

donde x_{ij} representa cada elemento de la matriz Γ , para el cual norma Euclidiana fue aplicada. Al emplear el proceso de normalización, los valores numéricos inherentes a la matriz se transformaron efectivamente en un dominio difuso con un rango definido entre $[0, 1]$. Entonces, los pesos fueron transferidos al vector W ; hacia la matriz de normalización N_{Γ} para todos sus elementos, mediante:

$$W_{r_{ij}} = N_{\Gamma_{ij}} \cdot W_j \quad (\text{A.43})$$

Una vez establecido esto, fue posible determinar el mejor **IB** ideal y el peor **IW** ideal para cada columna. Con referencia a los vectores de impacto y peso, fue posible representar el impacto deseado mediante los signos $[+, -]$, indicando así el aumento o disminución deseado para cada parámetro. Los

ectores $\mathbf{IB}$ e $\mathbf{IW}$ se obtuvieron mediante las siguientes expresiones:

$$\mathbf{IB}_j = \max(\mathbf{W}_{\Gamma_j}) \quad \mathbf{IW}_j = \min(\mathbf{W}_{\Gamma_j}) \quad (\text{A.44})$$

El paso siguiente consistió en calcular la distancia euclidiana entre los candidatos y los vectores $\mathbf{IB}$ e $\mathbf{IW}$ para cada columna. Esto dio como resultado la generación de la distancia positiva, $\mathbf{P}_d$, y la distancia negativa, $\mathbf{N}_d$, que se calcularon utilizando las siguientes expresiones basadas en los elementos de la matriz $\mathbf{N}_{\Gamma}$:

$$\mathbf{P}_d = \sqrt{\sum_{i=1}^n (\mathbf{IB}_j - \mathbf{P}_{\Gamma_{ij}})^2} \quad \mathbf{N}_d = \sqrt{\sum_{i=1}^n (\mathbf{IW}_j - \mathbf{N}_{\Gamma_{ij}})^2} \quad (\text{A.45})$$

La puntuación de cada candidato o *Score* para cada fila de la matriz $\mathbf{N}_{\Gamma}$ se obtuvo entonces mediante la siguiente expresión:

$$\text{Score} = \frac{\mathbf{N}_d}{\mathbf{N}_d + \mathbf{P}_d} \quad (\text{A.46})$$

El procedimiento completo es resumido en el Algorithm 2:

Algorithm 2 TOPSIS applied for candidate evaluation

Require: Γ_{ij} Candidate matrix, $W_j = [w_1, \dots, w_n]$ Weight vector, $I_j = [i_1, \dots, i_n]$ Impact vector

Ensure: *Score*

▷ Value between [0, 1] indicating the candidate score

1: **Matrix Normalization**

$$\mathbf{N}_{\Gamma_{ij}} = \frac{\Gamma_{ij}}{\sqrt{\sum_{i=1}^n \sum_{j=1}^n (\Gamma_{ij})^2}}$$

▷ Normalization of the candidate matrix

2: **Weight Application**

3: **for** i **in** $\mathbf{N}_{\Gamma_i}$ **do**

4: **for** j **in** W_j **do**

5: $\mathbf{W}_{\Gamma_{ij}} \leftarrow \mathbf{N}_{\Gamma_{ij}} * W_j$ ▷ Weight application to the elements of the normalized candidate matrix

6: **end for**

7: **end for**

8: **Ideal Solution Calculation**

9: **if** $I_j == '+'$ **then**

10: $\mathbf{IB}_j = \max(\mathbf{W}_{\Gamma_j})$

▷ Best ideal

11: $\mathbf{IW}_j = \min(\mathbf{W}_{\Gamma_j})$

▷ Worst ideal

12: **else**

13: $\mathbf{IW}_j = \max(\mathbf{W}_{\Gamma_j})$

14: $\mathbf{IB}_j = \min(\mathbf{W}_{\Gamma_j})$

15: **end if**

16: **Euclidean Distance Calculation**

$\mathbf{p}_d \leftarrow \sqrt{\sum_{i=1}^n (\mathbf{IB}_j - \mathbf{W}_{\Gamma_{ij}})^2}$ ▷ Positive Euclidean distance between candidates and the best ideal

$\mathbf{n}_d \leftarrow \sqrt{\sum_{i=1}^n (\mathbf{IW}_j - \mathbf{W}_{\Gamma_{ij}})^2}$ ▷ Negative Euclidean distance between candidates and the worst ideal

17: **Score Calculation**

$$\text{Score} \leftarrow \mathbf{n}_d / (\mathbf{n}_d + \mathbf{p}_d)$$

▷ Final score for each candidate

La técnica TOPSIS identifica la opción candidata óptima dentro de un conjunto específico en función de un algoritmo de planificación de ruta determinado y de parámetros ajustados. Esta técnica limita el espacio de búsqueda a un número finito de candidatos que se alinean bien con las características deseadas del vehículo, reduciendo así el número de iteraciones innecesarias. Este enfoque permite el desarrollo de una trayectoria factible en términos de evasión de obstáculos, así como en relación con los ángulos de dirección factibles, las velocidades alcanzables y la aceleración factible. Con este fin, se consideró esencial la adición de cuatro criterios complementarios para facilitar un proceso de toma de decisiones más generalizable.

- Rv_d : La distancia entre el vehículo autoconducido y el vehículo trasero se puede determinar empleando la siguiente ecuación, a partir de la distancia euclidiana:

$$Rv_d = \sqrt{(d_{v1} - s_{v1})^2 + (s_{v2} - s_{v2})^2} \quad (A.47)$$

donde d_{vn} denota la posición del n -ésimo vehículo sobre el eje d , mientras s_{vn} representan la posición n -ésimo vehículo sobre el eje lateral s .

- P_c : La posición relativa del vehículo respecto del centro del carril se determina por la diferencia de coordenadas entre el centro del eje delantero y el centro del propio carril. Este valor se puede obtener de la siguiente expresión:

$$P_c = \sqrt{(s_v - s_{CL})^2} \quad (A.48)$$

El término s_v es definido como la posición del n -ésimo vehículo sobre el eje s . Adicionalmente, s_{CL} es definido como el centro del carril en el eje lateral s .

- B_d : La distancia necesaria para el frenado de emergencia es una función de la velocidad del vehículo y se puede determinar a partir de:

$$B_d = \frac{v^2}{2 \cdot a} \quad (A.49)$$

donde v representa la velocidad máxima del vehículo, mientras que la distancia calculada permite ajustar la distancia de frenado a velocidades más bajas a lo largo de la trayectoria. El valor de a significa la desaceleración. En este estudio, se asumió que el valor de desaceleración constante sería -5 m/s^2 . Esto implica que el sistema de frenado del vehículo es capaz de reducir su velocidad a una tasa de 5 m/s^2 .

- LC : La cantidad de transiciones de carril ejecutadas por la trayectoria generada se calculó utilizando las coordenadas del vehículo $d(t)$ y $d(t-1)$, junto con el ancho del carril w_l .

$$LC = \sum_{i=1} \left[\frac{x_i}{w_l} - \frac{x_{i-1}}{w_l} \right] \quad (A.50)$$


Resultados experimentales

Para la simulación de resultados se consideró el circuito mostrado en la Figura A.13. y se desarrollaron los siguientes experimentos:


Experimento 1: Variación de velocidad

Inicialmente se realizó una prueba de control en la que el vehículo autónomo atravesó el circuito sin obstáculos y variando la velocidad máxima. La prueba comenzó a 50km/h y llegó hasta los 120km/h con incrementos de 10km/h. Se contrastaron los vectores resumidos en la Tabla A.6 y el modelo Core TOPSIS, el cual solo emplea los criterios $\{\alpha, \nu, a\}$


Los resultados de este procedimiento experimental se ilustran en la Figura A.17. Los hallazgos sugieren que a velocidades más bajas, los modelos exhibieron un comportamiento comparable, con la excepción de Core TOPSIS, que demostró un desempeño ligeramente disminuido debido a la consideración de un número limitado de criterios. Esto subrayó la importancia de incorporar una gama más completa de información para una toma de decisiones efectiva. Se observó que, a medida que aumentaban las velocidades, algunos modelos exhibieron una tendencia a alcanzar una meseta en el desempeño. Esto se evidenció por el modelo conservador y Core TOPSIS. Sin embargo, el modelo conservador mostró niveles superiores de comodidad al permanecer en una posición fija dentro de su carril y evitar cambios de carril innecesarios. A velocidades más altas, se hizo evidente que el modelo agresivo se estaba acercando a su límite, aunque esto estuvo acompañado de una disminución en la comodidad de los ocupantes. En contraste, el estilo moderado demostró un desempeño óptimo en las métricas en un rango de velocidades más altas.



(a) Métrica *Efficiency*.



(b) Métrica *Comfort*.



(c) Métrica *LCQFI*.

Figura A.17: Resultados de los modelos sobre diferentes límites de velocidad.

Experimento 2: Obstáculos estáticos

Este experimento replicó las condiciones de velocidad del experimento anterior, con la inclusión de obstáculos estáticos en la carretera. Los datos resultantes se presentan en la Figura A.18. A medida que se aumentó la velocidad de la simulación, se hizo cada vez más evidente que los obstáculos representaban

un desafío significativo. Mientras permanecían estacionarios, la mayoría de las colisiones ocurrieron en las secciones curvilíneas de la carretera a velocidades elevadas. El modelo Core TOPSIS demostró un desempeño en modesto en comparación con los estilos de conducción alternativos. El modelo agresivo exhibió un patrón similar, con la frecuencia de colisiones aumentando a medida que su velocidad se acercaba al límite de velocidad establecido. El estilo moderado demostró un desempeño sólido con respecto a la métrica de seguridad, particularmente cuando se lo compara con las otras métricas. Este comportamiento exhibido por el estilo moderado puede describirse como un ejemplo de un conductor hábil y experimentado que es capaz de mantener un equilibrio entre velocidad y seguridad. En última instancia, el modelo conservador exhibió la frecuencia de colisiones más baja, ya que priorizó la comodidad y la seguridad.




Figura A.18: Resultados con presencia de obstáculos estáticos.

Experimento 3: Obstáculos dinámicos

Para investigar el impacto de las condiciones variables del tráfico en la dinámica de los vehículos, se repitió el experimento con los obstáculos estáticos del experimento anterior, pero ahora con otros vehículos en la carretera. Estos vehículos mostraron trayectorias erráticas, ya que algunos viajaban a baja velocidad y permanecían en un solo carril, mientras que otros realizaban cambios de carril innecesarios o cruzaban más de dos carriles en una sola maniobra para impedir el movimiento. Los resultados se presentan en la Figura A.19.

Handwritten signature and date: 2023




Figura A.19: Resultados con presencia de obstáculos dinámicos.

Los resultados indican que el rendimiento de modelos específicos se vio afectado por el aumento de la velocidad máxima del vehículo. En comparación con los otros modelos, el modelo Core TOPSIS experimentó el mayor número de colisiones, una tendencia que aumentó junto con la velocidad de simulación. El estilo agresivo demostró un patrón comparable debido a su inclinación hacia los cambios de carril y el aumento de la velocidad. Por el contrario, el modelo conservador experimentó predominantemente colisiones traseras debido a la prevalencia de altas velocidades en el tráfico circundante. El estilo moderado logró un equilibrio óptimo en todas las métricas al priorizar la conducción estable a una velocidad adecuada.

Experimento 4: Comparación con otras técnicas de última generación

La última etapa del experimento consistió en un análisis comparativo de los modelos propuestos en este estudio, centrándose específicamente en el modelo de estilo de conducción moderado que se había probado anteriormente. Para la comparación se emplearon las siguientes metodologías:

- **Constrain Driven Method (CDM) [71]:** Este método evalúa cada trayectoria de acuerdo con restricciones preestablecidas en cuanto a aceleración, velocidad y ángulos de dirección. En caso de que se cumpla una restricción, la trayectoria se considera inaceptable y, en consecuencia, se excluye de cualquier consideración posterior.
- **Long Short Term Memory (LSTM):** Este modelo utiliza la base de datos NGSIM [72] y genera una trayectoria para evitar colisiones [73].

- Deep Q-Learning Network (DQN): El modelo de aprendizaje de refuerzo fue un DQN entrenado con un conjunto de datos propios para generar políticas de la toma de decisiones en carreteras [74]

En primer lugar, se realizó una comparación con la presencia de obstáculos estáticos y a distintas velocidades: 50, 60, 70, 80, 90, 100, 110, and 120 km/h. Los resultados de esta comparación se pueden observar en la Figura A.20.




Figura A.20: Comparativo con métodos del estado del arte.

El modelo de estilo de conducción moderado demostró un desempeño satisfactorio en todos los límites de velocidad, aunque hubo ligeros impactos en la seguridad y el confort a velocidades superiores a 100 km/h. Con respecto a las metodologías de última generación, el desempeño del modelo CDM disminuyó después de 60 km/h, como consecuencia del agotamiento de las trayectorias disponibles resultante de su proceso de evaluación inflexible. El modelo LSTM exhibió características de desempeño análogas a las observadas en el modelo moderado; sin embargo, demostró una disminución notable en su desempeño por encima de velocidades de 90 km/h. Esto se debió a su incapacidad para generar múltiples trayectorias, lo que limitaba la velocidad máxima a la que podía viajar el vehículo. Por último, el modelo DQN exhibió características de desempeño comparables a las del estilo de conducción moderado. Si bien hubo una ligera limitación en la velocidad, el modelo demostró un nivel aceptable de seguridad. Como modelo de aprendizaje por refuerzo, su desempeño fue estable y se centró en un estilo de conducción específico, ya que fue entrenado específicamente para generar políticas de toma de decisiones.

Para facilitar una segunda comparación, el escenario se amplió para abarcar tanto vehículos estáticos

60

como dinámicos. Los resultados de esta comparación se muestran en la Figura A.21. Los resultados del estudio demuestran que la presencia de obstáculos dinámicos tiene un marcado impacto en la dinámica de conducción. En el caso del modelo CDM, el rendimiento alcanzó una meseta a una velocidad de 60 km/h . El estilo moderado demostró un equilibrio en todas las métricas debido a su enfoque en la conducción estable, con un buen rendimiento hasta los 90 km/h . Sin embargo, más allá de este límite, hubo un ligero compromiso en seguridad y comodidad. En el caso del modelo LSTM, el rendimiento se mantuvo constante hasta una velocidad de 70 km/h , más allá de la cual comenzaron a surgir problemas con respecto a la seguridad y la comodidad. Con respecto al modelo DQN, el rendimiento se mantuvo estable hasta una velocidad de 100 km/h , más allá de la cual comenzó a declinar. Esto puede atribuirse a aspectos del entrenamiento del modelo. Cabe señalar que las condiciones en este escenario son particularmente exigentes, dado que el comportamiento exhibido por otros vehículos no se alinea con el que se observa típicamente en una situación de tráfico del mundo real. El modelo propuesto representa una contrapropuesta a los modelos de toma de decisiones existentes que aplican aprendizaje de refuerzo profundo. La característica distintiva del método propuesto es que no necesita datos extensos ni períodos de entrenamiento. Además, ofrece un proceso de ajuste más sencillo que potencialmente puede mejorar sus resultados. Por ejemplo, al considerar los criterios apropiados y ajustar adecuadamente los vectores de peso W e impacto I , el estilo moderado puede lograr mejores resultados.




Figura A.21: Comparativo con métodos del estado del arte, con obstáculos estáticos y dinámicos.

Adicionalmente, se realizó un análisis de tiempos para determinar el tiempo requerido por el esquema para la generación y evaluación de trayectorias, con el objetivo de seleccionar una trayectoria que sirviera

como referencia de control para el sistema de navegación del vehículo. Cabe señalar que el tiempo de respuesta del módulo de control no fue incluido en esta investigación debido a que el alcance de esta investigación no abarcó tales consideraciones. Cabe señalar que el tiempo de respuesta puede variar dependiendo del número de criterios y del número de puntos presentes en la trayectoria. Esto se debe a que la información generada durante el proceso de planificación de la trayectoria sufre una compresión. A medida que aumenta el número de puntos, el proceso de compresión se vuelve progresivamente más lento. La Tabla A.7. presenta los resultados de los experimentos realizados con diferentes límites de velocidad y presencia de obstáculos, con cada modelo y método evaluado en términos de sus respectivos tiempos de ejecución.

Tabla A.7: Tiempo de ejecución de cada modelo en diferentes condiciones

	Speed	CMD	LSTM	DQN	Core TOPSIS
Sin obstáculos	50 km/h	256 ms	224 ms	205 ms	197 ms
	120 km/h	293 ms	279 ms	238 ms	241 ms
Obstáculos estáticos	50 km/h	415 ms	290 ms	273 ms	268 ms
	120 km/h	487 ms	327 ms	319 ms	304 ms
Obstáculos dinámicos	50 km/h	560 ms	385 ms	340 ms	339 ms
	120 km/h	622 ms	410 ms	402 ms	390 ms

Se puede observar que el tiempo de respuesta de todos los modelos aumentó en conjunto con la aceleración y la presencia de obstáculos. Este fenómeno fue particularmente pronunciado en los modelos más básicos, que exhibieron una capacidad disminuida para identificar trayectorias óptimas. Es importante destacar que el proceso de planificación de trayectorias no genera criterios adicionales, sino que estos se derivan de la información producida durante esta fase del proceso. En este caso de estudio, el estilo de conducción moderado fue tomado en cuenta en la propuesta. Se puede observar que debido a su bajo costo computacional, el esquema propuesto tuvo tiempos de respuesta ligeramente inferiores en comparación con los enfoques de aprendizaje profundo y aprendizaje de refuerzo profundo. Además, debe notarse que en este caso particular, se omitió un período de entrenamiento, lo que ya proporciona una ventaja significativa en comparación con estos métodos antes mencionados.

B. Tesis de maestría en desarrollo

	REVISIÓN DE AVANCE DE PROYECTO DE TESIS PARA LA EVALUACIÓN DE LA MATERIA DE SEMINARIO DE INVESTIGACIÓN III	Código: CENIDET-AC-004-M11
	Referencia a la Norma ISO 9001:2008 7.1, 7.2.1, 7.5.1, 7.6, 8.1, 8.2.4	Revisión: 1
		Página 1 de 4

Cuernavaca, Mor., a 25 de junio de 2024

Título de la tesis:	Análisis de algoritmos de visión por computadora para un asistente de mantenimiento de carril
Estudiante:	SERGIO ÁLVAREZ SILVA
Director y codirector de tesis:	DR. DANTE MÚJICA VARGAS, DR. NIMROD GONZÁLEZ FRANCO

En la siguiente tabla se asientan las calificaciones considerando la información escrita y oral. La escala de calificaciones para el promedio general es de 0 a 100 y la mínima calificación aprobatoria es de 70. Así también para que esta acta tenga validez debe contener la calificación de al menos dos de los revisores y del director y/o codirector de tesis. En el caso de que algún revisor sea externo o por requerimientos oficiales no esté presente en la evaluación, éste puede evaluar y firmar mediante la digitalización de la presente acta, siendo el primero en asentar calificación y posteriormente los demás miembros evalúan y firman de forma autógrafa el documento digitalizado.

CRITERIOS	REVISOR 1	REVISOR 2	REVISOR 3	DIRECTOR y/o CODIRECTOR (promedio)
Estructura y claridad del informe (10%, poner calificación de 0 a 10)	10	10		9
Presentación oral (10%, poner calificación de 0 a 10)	8	5		8
Avance del proyecto de tesis (30%, poner calificación de 0 a 30) -Avance en el cumplimiento de los objetivos planteados en la propuesta de tesis -Avance en el cumplimiento de las metas establecidas	30	30		27
Resultados preliminares (40%, poner calificación de 0 a 40) -Análisis de los resultados preliminares obtenidos	40	40		37
Actividades para el cierre del proyecto de tesis y obtención de resultados finales (10%, poner calificación de 0 a 10)	10	10		8
Suma	98	95		89
Promedio General				91


DR. DANTE MÚJICA VARGAS
Director de tesis


DR. NIMROD GONZÁLEZ FRANCO
Codirector de tesis


DR. NOE ALEJANDRO CASTRO SANCHEZ
Revisor 1


DR. JUAN GABRIEL GONZÁLEZ BERNAL
Revisor 2

Revisor 3

C.c. Dpto. Servicios Escolares
Estudiante/Expediente

CENIDET-AC-004-M11

Rev. 1

199

	PRESENTACIÓN DE RESULTADOS DEL PROYECTO DE INVESTIGACIÓN	Código: CENIDET-AC-004-M12
	Referencia a la Norma ISO 9001:2008 7.1, 7.2.1, 7.5.1, 7.6, 8.1, 8.2.4	Revisión: 1
		Página 1 de 5

Cuernavaca, Mor., a 12 de diciembre de 2024


Título de la tesis:	Análisis de algoritmos de visión por computadora para un asistente de mantenimiento de carril
Estudiante:	SERGIO ÁLVAREZ SILVA
Director y codirector de tesis:	DR. DANTE MÚJICA VARGAS, DR. NIMROD GONZÁLEZ FRANCO

En la siguiente tabla se asientan las calificaciones considerando la información escrita y oral. La escala de calificaciones para el promedio general es de 0 a 100 y la mínima calificación aprobatoria es de 70. Así también para que esta acta tenga validez debe contener la calificación de al menos dos de los revisores y del director y/o codirector de tesis. En el caso de que algún revisor sea externo o por requerimientos oficiales no esté presente en la evaluación, éste puede evaluar y firmar mediante la digitalización de la presente acta, siendo el primero en asentar calificación y posteriormente los demás miembros evalúan y firman de forma autógrafa el documento digitalizado.

CRITERIOS	REVISOR 1	REVISOR 2	REVISOR 3	DIRECTOR y/o CODIRECTOR (promedio)
Estructura y claridad del Informe (10%, poner calificación de 0 a 10)	10	10		10
Presentación oral (10%, poner calificación de 0 a 10)	10	10		10
Cumplimiento de los objetivos y metas planteados en la propuesta de tesis (20%, poner calificación de 0 a 20)	20	20		20
Entrega de resultados del proyecto de tesis (60%, poner calificación de 0 a 60) -Siguiendo la estructura del documento de tesis	50	50		50
Suma	90	90		90
Promedio General				90


DR. DANTE MÚJICA VARGAS
Director de tesis


DR. NIMROD GONZÁLEZ FRANCO
Codirector de tesis


DR. NOE ALEJANDRO CASTRO SANCHEZ
Revisor 1


DR. JUAN GABRIEL GONZÁLEZ SERNA
Revisor 2

Revisor 3

C.c.p. Dpto. servicios Escolares
Estudiante/ Expediente

CENIDET-AC-004-M12

Rev. 1

Reporte Final del Periodo Sabático

499

	PRESENTACIÓN DE RESULTADOS DEL PROYECTO DE INVESTIGACIÓN		Código: CENIDET-AC-004-M12
	Referencia a la Norma ISO 9001:2008 7.1, 7.2.1, 7.5.1, 7.6, 8.1, 8.2.4		Revisión: 1
			Página 5 de 5

ACTA DE PRESENTACIÓN DE RESULTADOS DE INVESTIGACIÓN

Los abajo firmantes, miembros del Comité Tutorial de la tesis titulada *Análisis de algoritmos de visión por computadora para un asistente de mantenimiento de carril*, que realiza el estudiante SERGIO ALVAREZ SILVA, bajo la dirección del DR. DANTE MUJICA VARGAS y la codirección del DR. NIMROD GONZÁLEZ FRANCO, certifican que el día 22 de noviembre de 2024, se reunieron a las 10:00 hrs. para evaluar el documento y la presentación de resultados de investigación de la citada tesis.

Una vez evaluada la presentación del sustentante y habiéndose realizado los cuestionamientos necesarios, este comité decide:

- ☒ Aceptar el trabajo, considerando las observaciones del Comité Tutorial.
- ☐ Se propone un cambio de título por considerarlo más adecuado al alcance del trabajo. Este nuevo título será:

- ☐ Aceptar la propuesta de modificaciones al alcance del trabajo, por considerarla justificada ya que en este caso:


- ☐ Se ampliaron los objetivos originales.
- ☐ Se redujeron, limitaron o modificaron por causas de fuerza mayor.

- ☐ No se aceptó como terminado el trabajo.

Las observaciones del Comité Tutorial y las correcciones a realizar por el tesista se asientan en la hoja de observaciones adjunta.


DR. DANTE MUJICA VARGAS
Director de tesis


DR. NIMROD GONZÁLEZ FRANCO
Codirector de tesis


DR. NOÉ ALEJANDRO CASTRO SANCHEZ
Revisor 1


DR. JUAN GABRIEL GONZÁLEZ SERNA
Revisor 2

Revisor 3

C.p. Dpto. servicios Escolares
Estudiante/Expediente

CENIDET-AC-004-M12

Rev. 1

	REVISIÓN DE AVANCE DE PROYECTO DE TESIS PARA LA EVALUACIÓN DE LA MATERIA DE SEMINARIO DE INVESTIGACIÓN II	Código: CENIDET-AC-004-M10
	Referencia a la Norma ISO 9001:2008 7.1, 7.2.1, 7.5.1, 7.6, 8.1, 8.2.4	Revisión: 1
		Página 1 de 4

Cuernavaca, Mor., a 26 de junio de 2024

Título de la tesis:	Realce de iluminación para conducción autónoma en escenas nocturnas
Estudiante:	ENRIQUE HERNÁNDEZ GÓMEZ
Director y codirector de tesis:	DR. DANTE MÚJICA VARGAS, DR. JUAN GABRIEL GONZALEZ SERNA

En la siguiente tabla se asientan las calificaciones considerando la información escrita y oral. La escala de calificaciones para el promedio general es de 0 a 100 y la mínima calificación aprobatoria es de 70. Así también para que esta acta tenga validez debe contener la calificación de al menos dos de los revisores y del director y/o codirector de tesis. En el caso de que algún revisor sea externo o por requerimientos oficiales no esté presente en la evaluación, éste puede evaluar y firmar mediante la digitalización de la presente acta, siendo el primero en asentar calificación y posteriormente los demás miembros evalúan y firman de forma autógrafa el documento digitalizado.

CRITERIOS	REVISOR 1	REVISOR 2	REVISOR 3	DIRECTOR y/o CODIRECTOR (promedio)
Estructura y claridad del informe escrito (10%, poner calificación de 0 a 10)	8	9		9
Presentación oral (10%, poner calificación de 0 a 10)	8	9		9
Revisión y Asimilación del estado del arte (20%, poner calificación de 0 a 20) -Al menos 25 referencias adicionales)	18	17		18
Metodología para desarrollo y solución del proyecto de tesis (25%, poner calificación de 0 a 25) El proyecto puede ser un prototipo, modelo, programa, sistema -Evaluar metodología que siga un procedimiento claro y coherente.	23	23		23
Avance del proyecto de tesis (25%, poner calificación de 0 a 25) -Avance en el cumplimiento de los objetivos planteados en la propuesta de tesis -Avance en el cumplimiento de las metas establecidas	23	23		23
Claridad en la descripción de las actividades futuras (10%, poner calificación de 0 a 10)	9	9		9
Suma	89	90		91
Promedio General				


 DR. DANTE MÚJICA VARGAS

Director de tesis


 DR. JUAN GABRIEL GONZALEZ SERNA

Codirector de tesis


 DR. NOÉ ALEJANDRO CASTRO SANCHEZ

Revisor 1


 DR. NIMROD GONZÁLEZ FRANCO

Revisor 2

Revisor 3

C.c.p. Dpto. servicios Escolares
Estudiante/ Expediente

CENIDET-AC-004-M10

Rev. 1



	REVISIÓN DE AVANCE DE PROYECTO DE TESIS PARA LA EVALUACIÓN DE LA MATERIA DE SEMINARIO DE INVESTIGACIÓN III	Código: CENIDET-AC-004-M11
	Referencia a la Norma ISO 9001:2008 7.1, 7.2.1, 7.5.1, 7.6, 8.1, 8.2.4	Revisión: 1
		Página 1 de 4

Cuernavaca, Mor., a 12 de diciembre de 2024

Título de la tesis:	Realce de Iluminación para conducción autónoma en escenas nocturnas
Estudiante:	ENRIQUE HERNÁNDEZ GÓMEZ
Director y codirector de tesis:	DR. DANTE MÚJICA VARGAS, DR. JUAN GABRIEL GONZALEZ SERNA

En la siguiente tabla se asientan las calificaciones considerando la información escrita y oral. La escala de calificaciones para el promedio general es de 0 a 100 y la mínima calificación aprobatoria es de 70. Así también para que esta acta tenga validez debe contener la calificación de al menos dos de los revisores y del director y/o codirector de tesis. En el caso de que algún revisor sea externo o por requerimientos oficiales no esté presente en la evaluación, esto puede evaluar y firmar mediante la digitalización de la presente acta, siendo el primero en asentar calificación y posteriormente los demás miembros evalúan y firman de forma autógrafa el documento digitalizado.

CRITERIOS	REVISOR 1	REVISOR 2	REVISOR 3	DIRECTOR y/o CODIRECTOR (promedio)
Estructura y claridad del informe (10%, poner calificación de 0 a 10)	10	9		9
Presentación oral (10%, poner calificación de 0 a 10)	8	8		8
Avance del proyecto de tesis (30%, poner calificación de 0 a 30) -Avance en el cumplimiento de los objetivos planteados en la propuesta de tesis -Avance en el cumplimiento de las metas establecidas	26	27		26
Resultados preliminares (40%, poner calificación de 0 a 40) -Análisis de los resultados preliminares obtenidos	38	38		38
Actividades para el cierre del proyecto de tesis y obtención de resultados finales (10%, poner calificación de 0 a 10)	9	8		9
Suma	91	90		90
Promedio General				90

DR. DANTE MÚJICA VARGAS

Director de tesis

DR. ROBERTO ALEJANDRO CASTRO SANCHEZ

Revisor 1

DR. NIMFOD GONZÁLEZ FRANCO

Revisor 2

DR. JUAN GABRIEL GONZALEZ SERNA

Codirector de tesis

Revisor 3

C.c.p. Dpto. servicios Escolares
Estudiantil/Expediente

CENIDET-AC-004-M11

Rev. 1

97 9

C. Tesis de maestría finalizadas



EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



CERTIFICACIÓN DE ACTA DE EXAMEN DE GRADO DE MAESTRÍA



El suscrito Director del Centro Nacional de Investigación y Desarrollo Tecnológico certifica que en el Libro para Actas de Examen de Grado de Maestría N° 2 autorizado el día 16 del mes de marzo del 2020 por la Dirección de Asuntos Escolares y Apoyo a Estudiantes de la Dirección General del Tecnológico Nacional de México, se encuentra asentada en la foja número 183 el acta que a la letra dice:

En la ciudad de Cuernavaca, Morelos, a los veintiocho días del mes mayo de 2024 siendo las 11:06 horas, se reunieron en el auditorio del Centro Nacional de Investigación y Desarrollo Tecnológico, clave 171IT0001W, el jurado integrado por:

Presidente: Doctor en Ciencias de la Computación – Noé Alejandro Castro Sánchez.
Céd. Prof. (08701806)

Secretario: Doctor en Ciencias de la Computación – Nimrod González Franco.
Céd. Prof. (11088913)

Vocal: Doctor en Comunicaciones y Electrónica – Dante Mújica Vargas.
Céd. Prof. (09131756)

Y de acuerdo con las disposiciones reglamentarias en vigor, se procedió a efectuar el examen de Grado de Maestría al **C. ANDRÉS ANTONIO ARENAS MUÑIZ**, número de control: **M22CE043**, aspirante al grado de Maestro en Ciencias de la Computación.

Tomando en cuenta el contenido de la tesis cuyo título es: **"Implementación de estrategias avanzadas utilizando TOPSIS para la selección óptima de trayectorias en vehículos autoconducidos"**, dirigida por el Dr. Dante Mújica Vargas, una vez concluido el examen oral, dictaminó que fuera: **APROBADO CON MENCIÓN HONORIFICA**.

El Presidente del Jurado le hizo saber al sustentante el resultado obtenido, el Código de Ética Profesional y le tomó la protesta de Ley. Dándose por terminado el acto a las 12:25 horas, y una vez escrita, leída y aprobada fue firmada para constancia por las personas que en el acto intervinieron, para los efectos legales a que haya lugar se asienta la presente.

Rubrican

Se extiende esta certificación a los veintiocho días del mes mayo de 2024.

COTEJÓ

Jefa del Departamento
de Servicios Escolares
MTI. María Elena Gómez Torres

DIRECTOR
Dr. Arturo Ernesto Mares Gardea



C.N.I.D.T.
CENTRO NACIONAL
DE INVESTIGACIÓN
Y DESARROLLO
TECNOLÓGICO
MÉXICO

D. Artículos científicos en revistas indizadas enviados



Dr. Dante Mújica Vargas <dante.mv@cenidet.tecnm.mx>

Submission Confirmation for A hybrid deep learning-fuzzy inference scheme for driving supervision

1 mensaje

Intelligenza Artificiale <em@editorialmanager.com>
Responder a: Intelligenza Artificiale <editorial@iospress.nl>
Para: Dante Mújica-Vargas <dante.mv@cenidet.tecnm.mx>

24 de julio de 2024, 20:44

Dear Dr. Mújica-Vargas,

Your submission entitled "A hybrid deep learning-fuzzy inference scheme for driving supervision" has been successfully received by Intelligenza Artificiale, and has been assigned manuscript number IA-240085.

You will be able to check the progress of your paper by logging on to Editorial Manager as an author. The URL is <https://www.editorialmanager.com/ia/>.

Thank you for submitting your work.

Kind regards,

Intelligenza Artificiale

In compliance with data protection regulations, you may request that we remove your personal registration details at any time. (Use the following URL: <https://www.editorialmanager.com/ia/login.asp?a=r>). Please contact the publication office if you have any questions.

Handwritten initials and a signature in blue ink.

Intelligenza Artificiale: Sage Journals

<https://journals.sagepub.com/home/ina>

Sage Journals

Intelligenza Artificiale

Impact Factor 1.9



Intelligenza Artificiale is the official journal of the Italian Association for Artificial Intelligence (AIXIA). Intelligenza Artificiale publishes rigorously reviewed articles (in English) in all areas of Artificial Intelligence, with a special attention to original contributions. It will also publish assessments of the state of the art in various areas of AI, and innovative ... | [View full journal description](#)

Browse by

[Most recent](#) [Most read](#) [Most cited](#) [Trending](#)

Articles most recently published online for this journal.



Free access

Research article

First published Nov 26, 2024

[BERT with an Augmented Cross-attention Decoder \(BERT-ACD\) for Binary and Fine-grained Multipoint Sentiment Detection](#)

Abubakar M. Ashir, Mohammed Abdulghani Taha



Free access

Research article

First published Sep 19, 2024

[Monte-Carlo Regret Minimization for Adversarial Team Games](#)

Luca Carminati, Federico Cacciamani



Free access

Research article

First published Aug 27, 2024

[A new perspective on optimizers: leveraging moreau-yosida approximation in gradient-based learning](#)

Alessandro Betti, Gabriele Ciravegna, Marco Gori, Stefano Melacci, Kevin Mottin, Frédéric Precioso



Free access

Research article

First published Jun 17, 2024

[Planning and learning to perceive in partially unknown environments](#)

Leonardo Lamanna

[View Onlinefirst Articles](#)[View Latest Issues](#)

Intelligenza Artificiale

A hybrid deep learning-fuzzy inference scheme for driving supervision

--Manuscript Draft--

Manuscript Number:	
Full Title:	A hybrid deep learning-fuzzy inference scheme for driving supervision
Short Title:	
Article Type:	Research Article
Keywords:	Real-time driving monitoring; Deep learning neural models; Type-1 Mamdani Fuzzy; Safe and risky driving state
Corresponding Author:	Dante Mujica-Vargas MEXICO
Corresponding Author Secondary Information:	
Corresponding Author's Institution:	
Corresponding Author's Secondary Institution:	
First Author:	Dante Mujica-Vargas
First Author Secondary Information:	
Order of Authors:	Dante Mujica-Vargas Antonio Luna-Álvarez Antonio Arenas-Muñiz Francisco Gallegos-Funes Alberto Rosales-Silva
Order of Authors Secondary Information:	
Abstract:	This study, based on empirical evidence, presents an embedded system for the real-time monitoring of driving states. This proposal is based on a pair of convolutional deep learning neural networks that facilitate the detection and quantification of driver eye, mouth, and head posture states. The values obtained were then processed using a fusion technique based on a Type-1 Mamdani Fuzzy module. This approach was employed to infer the driving state, with the intention of distinguishing between a safe and a risky driving state. In order to assess the efficacy of this proposal, a variety of standard metrics from the literature were employed in conjunction with two experiments. The results of these experiments indicate that the proposal demonstrates a level of performance that is superior to 92% in both instances.
Suggested Reviewers:	
Opposed Reviewers:	
Additional Information:	
Question	Response
By submitting this article I agree with the IOS Press author copyright agreement	Yes
By submitting this article I agree with the IOS Press privacy policy	Yes

Undefined 1 (2024) 1–5
IOS Press

A hybrid deep learning-fuzzy inference scheme for driving supervision

Dante Mújica-Vargas ^{a,*}, Antonio Luna-Álvarez ^b, Antonio Arenas-Muñiz ^a, Francisco Gallegos-Funes ^c and Alberto Rosales-Silva ^c

^a Departamento de Ciencias Computacionales, TecNM/CENIDET, Cuernavaca-Morelos, México
E-mail: {dante.mv,m22ce043}@cenidet.tecnm.mx

^b División de Estudios de Posgrado e Investigación, TecNM/ITChilpancingo, Chilpancingo-Guerrero, México
E-mail: jesús.la@chilpancingo.tecnm.mx

^c Sección de Estudios de Posgrado e Investigación, IPN-ESIME, Ciudad de México, México
E-mail: {fgallegosf,arosalesj}@ipn.mx

Abstract.

This study, based on empirical evidence, presents an embedded system for the real-time monitoring of driving states. This proposal is based on a pair of convolutional deep learning neural networks that facilitate the detection and quantification of driver eye, mouth, and head posture states. The values obtained were then processed using a fusion technique based on a Type-1 Mamdani Fuzzy module. This approach was employed to infer the driving state, with the intention of distinguishing between a safe and a risky driving state. In order to assess the efficacy of this proposal, a variety of standard metrics from the literature were employed in conjunction with two experiments. The results of these experiments indicate that the proposal demonstrates a level of performance that is superior to 92% in both instances.

Keywords: Real-time driving monitoring, Deep learning neural models, Type-1 Mamdani Fuzzy, Safe and risky driving state

1. Introduction

The act of driving a car is a complex and demanding task that requires the performance of a multitude of activities simultaneously. These include maintaining one's position on the road, changing lanes, observing the behavior of other drivers, anticipating potential hazards or crashes, and managing internal and external distractions. The ability to make decisions and control actions while driving is contingent upon the driver's vision. An understanding of how drivers observe and analyze the road scene, how this influences their thinking, and the causes of distraction is essential for the purpose of ensuring road safety. Advanced Driver Assistance Systems (ADAS) is a nascent automotive technology designed to enhance driver safety

and reduce human-caused crashes. In the evolution of automotive technology, ADAS is inextricably linked to vision-based driver assistance systems (VB-DAS) and driver monitoring systems (DMS). Due to their utility, these systems are becoming standard even in low- and medium-priced commercial vehicles. Lane Departure Warning, Automatic Emergency Braking, Forward Collision Warning, Adaptive Cruise Control, and other variations of these systems are becoming increasingly popular. However, in adverse conditions, these systems relinquish control to the driver, thereby ultimately acting in a manner dependent on the driver's condition or intentions. For this reason, it is of the utmost importance to regularly monitor the driver's inattentiveness in order to either warn the driver or to stop the vehicle if the driver does not react.

The present study is concerned with the issue of driver monitoring; in this regard, important contributions to the state of the art in this area have been

* Corresponding author. E-mail: dante.mv@cenidet.tecnm.mx.



Dr. Dante Mújica Vargas <dante.mv@cenidet.tecnm.mx>

ASOC-D-25-00201 - Confirming your submission to Applied Soft Computing Journal

- Mensaje

Applied Soft Computing <em@editorialmanager.com>

6 de enero de 2025, 15:12

Responder a: Applied Soft Computing <asoc@softcomputing.org>

Para: Dante Mújica-Vargas <dante.mv@cenidet.tecnm.mx>

Cari Dr. Mújica-Vargas,

Thank you for sending your manuscript A TOPSIS-based multi-attribute decision-making approach for trajectory selection within an obstacle-rich environment for consideration to Applied Soft Computing Journal. It has been assigned the following manuscript number: **ASOC-D-25-00201**. Please accept this message as confirmation of your submission.

*For submission status queries, please contact the editorial team through Editorial Manager. To contact the editor-in-chief directly, please use the contact form: <https://www.journals.elsevier.com/applied-soft-computing/editorial-board/mario-koppen>

When should I expect to receive the Editor's decision?

We publicly share the average editorial times for Applied Soft Computing Journal to give you an indication of when you can expect to receive the Editor's decision. These can be viewed here: http://journalinsights.elsevier.com/journals/1568-4946/review_speed

What happens next?

Here are the steps that you can expect as your manuscript progresses through the editorial process in the Editorial Manager (EM).

1. First, your manuscript will be assigned to an Editor and you will be sent a unique reference number that you can use to track it throughout the process. During this stage, the status in EM will be "With Editor".

2. If your manuscript matches the scope and satisfies the criteria of Applied Soft Computing Journal, the Editor will identify and contact reviewers who are acknowledged experts in the field. Since peer-review is a voluntary service, it can take some time but please be assured that the Editor will regularly remind reviewers if they do not reply in a timely manner. During this stage, the status will appear as "Under Review".

Once the Editor has received the minimum number of expert reviews, the status will change to "Required Reviews Complete".

3. It is also possible that the Editor may decide that your manuscript does not meet the journal criteria or scope and that it should not be considered further. In this case, the Editor will immediately notify you that the manuscript has been rejected and may recommend a more suitable journal.

For a more detailed description of the editorial process, please see Paper Lifecycle from Submission to Publication: http://help.elsevier.com/app/answers/detail/a_id/160/p/8045/

How can I track the progress of my submission?

You can track the status of your submission at any time at <https://www.editorialmanager.com/ASOC>

Once there, simply:

1. Enter your username: Your username is: Dante

If you need to retrieve password details, please go to: [click here to reset your password](#)

2. Click on [Author Login]. This will take you to the Author Main Menu

3. Click on [Submissions Being Processed]

Many thanks again for your interest in Applied Soft Computing Journal.

Kind regards,
Editorial Manager

If you require further assistance, you are welcome to contact our Researcher Support team 24/7 by live chat and email or 24/5 by phone: <http://support.elsevier.com>

This journal uses the Elsevier Article Transfer Service. This means that if an editor feels your manuscript is more suitable for an alternative journal, then you might be asked to consider transferring the manuscript to such a journal. The recommendation might be provided by a Journal Editor, a dedicated Scientific Managing Editor, a tool assisted recommendation, or a combination. For more details see the journal guide for authors.

At Elsevier, we want to help all our authors to stay safe when publishing. Please be aware of fraudulent messages requesting money in return for the publication of your paper. If you are publishing open access with Elsevier, bear in mind that we will never request payment before the paper has been accepted. We have prepared some guidelines (<https://www.elsevier.com/connect/authors-update/seven-top-tips-on-stopping-apc-scams>) that you may find helpful, including a short video on identifying fake acceptance letters (<https://www.youtube.com/watch?v=05i8thD9XtE>). Please remember that you can contact Elsevier's Researcher Support team (<https://service.elsevier.com/app/home/supporthub/publishing>) at any time if you have questions about your manuscript, and you can log into Editorial Manager to check the status of your manuscript (https://service.elsevier.com/app/answers/detail/a_id/29155/c/10530/supporthub/publishing/kw/status/). #AU_ASOC#

To ensure this email reaches the intended recipient, please do not delete the above code

In compliance with data protection regulations, you may request that we remove your personal registration details at any time. (Remove my information/details). Please contact the publication office if you have any questions.

Handwritten signature and initials in blue ink.

Applied Soft Computing | Journal | ScienceDirect.com b...

<https://www.sciencedirect.com/journal/applied-soft-com...>

Applied Soft Computing

100% open access

15.8

7.2

CiteScore

Impact Factor

[Submit your article](#)
[Guide for authors](#)
[Menu](#)

[Search in this journal](#)

About the journal

The Official Journal of the World Federation on Soft Computing (WFSC) <http://www.softcomputing.org>

Applied Soft Computing is an international journal promoting an integrated view of **soft computing** to solve real life problems. Soft computing is a collection of methodologies, which aim to exploit ...

[View full aims & scope](#)
\$3730 ^①

Article publishing charge
for open access

6 days

Time to first decision

104 days

Review time

230 days

Submission to acceptance


[View all insights](#)
Editor-in-Chief
[View full editorial board](#)

Mario Köppen

Kyushu Institute of Technology, 680-4, Kawazu, Iizuka, Fukuoka 820-8502 JAPAN, Kitakyushu, 804-8550, Japan

Articles

[Latest published](#)
[Articles in press](#)
[Top cited](#)
[Most downloaded](#)
[Most popular](#)

Research article ☐ Abstract only

A novel multi-objective hybrid evolutionary algorithm based on variable weight strategy for distributed hybrid flowshop scheduling with batch processing machines and variable sublots

Handwritten signatures and marks at the bottom right of the page.

Applied Soft Computing Journal**A TOPSIS-based multi-attribute decision-making approach for trajectory selection within an obstacle-rich environment**

--Manuscript Draft--

Manuscript Number:	
Article Type:	Full Length Article
Keywords:	Autonomous Vehicles; Trajectory Prediction; Multiple Criteria Decision-Making (MCDM); Fuzzy Systems, TOPSIS Algorithm
Corresponding Author:	Dante Mujica-Vargas National Center for Research and Technological Development MEXICO
First Author:	Dante Mujica-Vargas
Order of Authors:	Dante Mujica-Vargas Andrés Muñoz-Arenas Antonio Luna-Álvarez Francisco Gallegos-Funes Alberto Rosales-Silva
Abstract:	This paper addresses the challenge of trajectory prediction in autonomous vehicles navigating obstacle-rich environments. In order to enhance decision-making, a novel approach is proposed which integrates multiple criteria decision-making with a low-cost fuzzy system. This approach has the benefit of optimising both flexibility and response time. The proposed methodology employs fifth-order polynomials for the construction of optimal trajectories and implements TOPSIS algorithms to incorporate driver experience through a weighted impact system. The model's efficacy was assessed through simulations conducted under both static and dynamic obstacle conditions. Performance was evaluated relative to state-of-art models, including LSTM and Deep Q-learning. The results demonstrate that the proposed approach attains a 15% enhancement in efficiency and a 20% improvement in safety scores relative to comparative methods. Furthermore, the incidence of collisions was diminished by 25%, and the time required for a response was reduced by 12% in comparison to the LSTM model. The results illustrate the effectiveness of our methodology in dynamic settings while maintaining operational latency and real-time adaptability. The model's capacity to balance diverse criteria makes it a compelling solution for autonomous driving applications in real-world settings.

A TOPSIS-based multi-attribute decision-making approach for trajectory selection within an obstacle-rich environment

Dante Mújica-Vargas^a, Andrés Muñoz-Arenas^a, Antonio Luna-Alvarez^c, Francisco Gallegos-Funes^b, Alberto Rosales-Silva^b

^aTecNM/CENIDET, Interior Internado Palmira S/N, Col. Palmira, Cuernavaca, 62490, Morelos, Mexico

^bTecNM/ITChilpancingo, Av. Jose Francisco Ruiz Massieu No. 5, Fracc. Villa Moderna, Chilpancingo, 39090, Guerrero, Mexico

^cIPN-SEPI-ESIME-Zacatenco, Av. Luis Enrique Erro S/N, Col. Zacatenco, Mexico City, 07738, Mexico City, Mexico

Abstract

This paper addresses the challenge of trajectory prediction in autonomous vehicles navigating obstacle-rich environments. In order to enhance decision-making, a novel approach is proposed which integrates multiple criteria decision-making with a low-cost fuzzy system. This approach has the benefit of optimising both flexibility and response time. The proposed methodology employs fifth-order polynomials for the construction of optimal trajectories and implements TOPSIS algorithms to incorporate driver experience through a weighted impact system. The model's efficacy was assessed through simulations conducted under both static and dynamic obstacle conditions. Performance was evaluated relative to state-of-art models, including LSTM and Deep Q-learning. The results demonstrate that the proposed approach attains a 15% enhancement in efficiency and a 20% improvement in safety scores relative to comparative methods. Furthermore, the incidence of collisions was diminished by 25%, and the time required for a response was reduced by 12% in comparison to the LSTM model. The results illustrate the effectiveness of our methodology in dynamic settings while maintaining operational latency and real-time adaptability. The model's capacity to balance diverse criteria makes it a compelling solution for autonomous driving applications in real-world settings.

Keywords:

Autonomous Vehicles, Trajectory Prediction, Multiple Criteria Decision-Making (MCDM), Fuzzy Systems, TOPSIS Algorithm

1. Introduction

The development of robust algorithms is essential for the autonomous navigation of self-driving vehicles in complex environments, such as highways. Such algorithms must be capable of providing suitable options for movement in order to effectively handle the uncertainty generated by interactions with other drivers and diverse obstacles. Furthermore, given the considerable variability in velocity along the trajectory, which can be attributed to a multitude of factors, it is imperative to deploy methodologies that are both adaptable and capable of rapid response. The creation of a single pathway can be achieved through the implementation of robust methodologies, which simultaneously satisfy the criteria of flexibility and rapid response. However, it should be noted that the solutions provided may lack sufficient precision to ensure the requisite level of safety is met. In contrast, the generation of multiple trajectories through the application of low-cost methodologies represents an effective approach for obtaining potential alternatives. However, this necessitates an additional process for the selection of the optimal trajectory. The selection method employed may influence the degree to which this option satisfies the requirements of flexibility and rapid response.

In recent years, there has been a significant increase in the use of deep learning techniques in the domains of trajectory planning and decision-making in autonomous vehicles. For example, Guo et al. [1] employed a convolutional neural network (CNN) for the purpose of analyzing the driving environment and predicting the most probable trajectory. In a similar manner, Wang et al. [2] proposed a model designed to emulate human driving behavior at intersections. Meanwhile, Shi et al. [3] employed a convolutional neural network-recurrent neural network hybrid to

III. Memorias en extenso en congresos



Book series

Communications in Computer and Information Science

 [Editors](#)

About this book series

Rationale

The CCIS series is devoted to the publication of proceedings of computer science conferences. Its aim is to efficiently disseminate original research results in informatics in printed and electronic form. While the focus is on publication of peer-reviewed full papers presenting mature work, inclusion of reviewed short papers reporting on work in progress is welcome, too. Besides globally relevant meetings with internationally representative program committees guaranteeing a strict peer-reviewing and paper selection process, conferences run by societies or of high regional or national relevance are also considered for publication. — [show all](#)

Electronic ISSN	Print ISSN
1865-0937	1865-0929

Series Editor

Gang Li, Joaquim Filipe, Zhiwei Xu

Abstracted and indexed in

DBLP
EI Compendex
INSPEC
Japanese Science and Technology Agency (JST)
Norwegian Register for Scientific Journals and Series
SCImago
SCOPUS
zbMATH

[Home](#) > [Conference proceedings](#)


Telematics and Computing

13th International Congress of Telematics and Computing, WITCOM 2024, Mazatlan, Mexico, November 4–8, 2024, Proceedings, Part I

| Conference proceedings | © 2024

Overview

Editors: [Miguel Félix Mata-Rivera](#), [Roberto Zagal-Flores](#), [Cristian Barria-Huidobro](#)

Part of the book series: [Communications in Computer and Information Science](#) (CCIS, volume 2249)

Included in the following conference series:

[WITCOM: International Congress of Telematics and Computing](#)

Conference proceedings info: WITCOM 2024.

About this book

This two-volume set constitutes the refereed proceedings of the 13th International Conference on Telematics and Computing, WITCOM 2024, which took place in Mazatlan, Mexico, during November 4–8, 2024.

The 41 full papers presented in this volume were carefully reviewed and selected from 91 submissions. The papers focus on the topics of environment monitoring, information systems, IoT, education, artificial intelligence techniques, cybersecurity, data science, and energy, with applications to different case of study.



AUTHOR

OF CONFERENCE WITCOM 2024

The organization of WITCOM is pleased to extend this recognition to

Dante Mújica-Vargas

For your participation with the paper "Deep learning and index fusion-based driving monitoring system" in the Telematics and Informatics Workshops and Conferences held from November 4th to 8th at the 13th International Conference: WITCOM 2024 in Mazatlán, Sinaloa, México



Dr. Miguel Félix Mata Rivera
CHAIRMAN WITCOM 2024

ID: 0376



Deep Learning and Index Fusion-Based Driving Monitoring System

Dante Mújica-Vargas¹ , Antonio Luna-Álvarez² ,
Francisco Gallegos-Funes³ , Alberto Rosales-Silva³ ,
and Antonio Rendón-Vargas²

¹ Departamento de Ciencias Computacionales, TecNM/CENIDET,
Chernavaca-Morelos, Mexico
dante.mv@cenidet.tecnm.mx

² División de Estudios de Posgrado e Investigación, TecNM/ITChilpancingo,
Chilpancingo Guerrero, Mexico

³ Sección de Estudios de Posgrado e Investigación, Instituto Politécnico
Nacional-ESIME, Ciudad de México, Mexico

Abstract. This empirical study presents an embedded system for real-time driving monitoring. This proposal is based on three convolutional deep learning neural models that allow detecting and quantifying the state of the driver's eyes, mouth, and head posture. From these values, a fusion technique is presented that allows inferring the state of the driver's head while driving. The effectiveness of this proposal is quantified using common metrics from the literature, which suggest a performance greater than 91%.

Keywords: Real-time driving monitoring · Deep learning neural models · Multi-index fusion technique

1 Introduction

Driving is a challenging task that requires the simultaneous performance of multiple activities. This includes staying in the road, changing lanes, observing other drivers' behavior, anticipating potential dangers or crashes, as well as managing internal and external distractions, among others. To make decisions and control actions while driving, drivers rely primarily on their vision. Ensuring road safety is critical to understand how drivers observe and analyze the scene, how it affects their reasoning, and what causes lapses in attention. Advanced Driver Assistance Systems (ADAS) is an emerging technology in the automotive industry with the goal of ensuring safety while driving and reducing traffic accidents due to human error. In the evolution of automotive technology, ADAS are inextricably linked to Vision-Based Driver Assistance Systems (VB-DAS) and Driver Monitoring Systems (DMS), which are becoming standard even in low- and mid-priced commercial vehicles due to their utility. Some popular variants of these systems include lane keeping assistants, automatic emergency braking, forward collision

© The Author(s), under exclusive license to Springer Nature Switzerland AG 2024
M. F. Mata-Rivera et al. (Eds.): WITCOM 2024, CCIS 2249, pp. 16–29, 2024.
https://doi.org/10.1007/978-3-031-77290-0_2



AUTHOR

OF CONFERENCE WITCOM 2024

The organization of WITCOM is pleased to extend this recognition to

Dante Mújica-Vargas

For your participation with the paper "Fine-tuning the TOPSIS technique and transferring knowledge of different driving styles" in the Telematics and Informatics Workshops and Conferences held from November 4th to 8th at the 13th International Conference: WITCOM 2024 in Mazatlán, Sinaloa, México



Dr. Miguel Félix Mata Rivera
CHAIRMAN WITCOM 2024

ID: 4854



Fine-Tuning the TOPSIS Technique and Transferring Knowledge of Different Driving Styles

Dante Mújica-Vargas¹✉, Andrés Arenas-Muñoz¹,
Francisco Gallegos-Funes², and Alberto Rosales-Silva²

¹ Departamento de Ciencias Computacionales, TecNM/CENIDET,
Cuernavaca-Morelos, Mexico
dante.mv@cenidet.tecnm.mx

² Sección de Estudios de Posgrado e Investigación, Instituto Politécnico,
Nacional-ESIME, Ciudad de México, Mexico

Abstract. This study investigates trajectory generation methods for automated driving by refining existing approaches using polynomial algorithms and TOPSIS. While initial heuristics adjusted vectors, alternative methods such as Bayesian optimization and experience transfer were explored. Bayesian optimization initially achieves higher efficiency and comfort scores (0.76 and 0.45), but experience transfer allows for adaptive driving styles, balancing metrics (efficiency 0.51-0.78, safety 0.38-0.56, comfort 0.22-0.38, LCFQI 0.36-0.64) according to driving style and static obstacles. Experience Transfer provides immediacy by leveraging prior knowledge without exhaustive search, making it a favorable choice for rapid, critical implementations in complex driving scenarios.

Keywords: Fine tuning · TOPSIS · Experience transfer · Automated driving

1 Introduction

As the use of decision-making capable systems increases, in specific the use of Multiple-Criteria Decision-Making (MCDM), the fields of application of such techniques expand to include self-driving vehicles. In this specific application, it is necessary to gather a great deal of information in order to ensure that the optimal option is selected. As the data is gathered through different onboard systems and sensors, the number of criteria could increase rapidly in these systems. This leads to the necessity of solving an optimization problem, namely the correct adjustment of the internal mechanisms of the MCDM methods. The Technique for Order of Preference by Similarity to the Ideal Solution (TOPSIS) comprises two adjustable mechanisms that permit the user to adjust the selection of an optimal solution. These mechanisms are represented by the vectors of weight W and impact I , which permit the user to set the importance of each criterion to a desired level. This ensures that the decision-making process is well fitted.

© The Author(s), under exclusive license to Springer Nature Switzerland AG 2024
M. F. Mata-Rivera et al. (Eds.): WITCOM 2024, CCIS 2249, pp. 293–308, 2024.
https://doi.org/10.1007/978-3-031-77290-0_19

85

82

F. Actividades Instituto Politécnico Nacional



EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



Instituto Politécnico Nacional
"La Técnica al Servicio de la Patria"

ESCUELA SUPERIOR DE INGENIERÍA MECÁNICA Y
ELECTRICA
UNIDAD ZACATENCO
SECCIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN
MAESTRÍA EN CIENCIAS EN INGENIERÍA ELECTRÓNICA

100 Aniversario del CECyT "Gonzalo Vázquez Vela"
60 Aniversario del Centro Cultural "Jaime Torres Bodet"
50 Aniversario de la ESIME Unidad Culhuacán,
ESIA Unidad Tecamachalco y de la Escuela Superior de Turismo
40 Aniversario del CIEMAD, CEPROBI y del CITEDI

Ciudad de México, 15 de julio de 2024

A quien corresponda:

Por medio de la presente se hace constar que el Dr. Dante Mújica Vargas colaboró activamente en la impartición de cursos de posgrado y asesorías de estudiantes de Maestría y Doctorado dentro de nuestro Programa de Maestría en Ciencias en Ingeniería Electrónica de la Sección de Estudios de Posgrado e Investigación de ESIME Unidad Zacatenco y también colaboró en el Doctorado en Comunicaciones y Electrónica de la ESIME Unidad Culhuacán asesorando en temas de inteligencia artificial, este programa también tiene por sede las instalaciones de la Maestría, estas actividades se realizaron durante el periodo de enero a julio de 2024.

ATENTAMENTE

Dr. Alberto Jorge Rosales Silva
Profesor Maestría Electrónica

Dr. Francisco Javier Callegos Funes
Profesor Maestría Electrónica

Unidad Profesional Adolfo López Mateos, Edificio No. 5 Tercer piso Col. Zacatenco, C.P. 07738, Gustavo A. Madero, Ciudad de México.
Tel: (55) 5729 6000 ext. 54585, 54587 sepuesime@ipn.mx



2024
Felipe Carrillo
PUERTO



Instituto Politécnico Nacional
"La Técnica al Servicio de la Patria"

**ESCUELA SUPERIOR DE INGENIERÍA
MECÁNICA Y
ELÉCTRICA
UNIDAD ZACATENCO**
SECCIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN



100 Aniversario del CECyT I "Gonzalo Vázquez Vela"
60 Aniversario del Centro Cultural "Jaime Torres Bodet"
50 Aniversario de la ESIME Unidad Cuahuacán,
ESIA Unidad Tecamachalco y de la Escuela Superior de Turismo
40 aniversario del CIEMAD, CEPROBI y del CITEDI

Asunto
Actividades Año Sabático

Ciudad de México, 31 de enero de 2025

Dr. Dante Mújica Vargas
Profesor Investigador
Departamento de Ciencias Computacionales CENIDET
PRESENTE

Por medio de la presente, me permito hacer constar que las actividades realizadas durante su estancia Sabática, las cuales corresponden al 100% de sus actividades especificadas en el plan de trabajo planteado en el proyecto académico: "Estudio y Aplicación de técnicas de Inteligencia Artificial para la asistencia de conducción en vehículos autónomos", han sido realizadas de manera satisfactoria durante el periodo comprendido del 1 de febrero del 2024 al 31 de enero del 2025, en la Sección de Estudios de Posgrado e Investigación de la Escuela Superior de Ingeniería Mecánica y Eléctrica Unidad Zacatenco

Sin más por el momento reciba un cordial saludo.

ATENTAMENTE
"La Técnica al Servicio de la Patria"


Dr. Francisco Javier Gallegos Funes
Profesor Investigador
Maestría en Ciencias en Ingeniería Electrónica
Instituto Politécnico Nacional, ESIME Zacatenco
fgallegosf@ipn.mx
Ext: 54633


Dr. Alberto Jorge Rosales Silva
Profesor Investigador
Maestría en Ciencias en Ingeniería Electrónica
Instituto Politécnico Nacional, ESIME Zacatenco
arosales@ipn.mx
Ext: 54633

Unidad Profesional Adolfo López Mateos, Edificio No. 5 Tercer piso Col. Zacatenco, CP. 07738, Gustavo A. Madero, Ciudad de México.

Tel: (55) 5729 6000 ext. 54586, 54587 sepi.esime.ipn.mx



[Handwritten marks]



SECRETARÍA
DE
EDUCACIÓN PÚBLICA

INSTITUTO POLITÉCNICO NACIONAL SECRETARÍA DE INVESTIGACIÓN Y POSGRADO

SIP-16

ACTA DE EXAMEN PREDOCTORAL

En la Ciudad de México, a las 16:00 horas del día 08 del mes de julio del año 2024 reunidos en el Aula Magna, designado para tal efecto, los

Profesores de la Sección de Estudios de Posgrado e Investigación:

Dr. Volodymyr Ponomaryov, Dra. Mariko Nakano, Dr. Alberto Jorge Rosales Silva,
Dr. Dante Mújica Vargas, Dr. Francisco Javier Gallegos Funes

designados para integrar el jurado de Examen Predoctoral para obtener el grado de: DOCTORADO EN COMUNICACIONES Y ELECTRÓNICA

de: Armando Adrián Miranda González

Con registro: B200280 y considerando que ha cumplido con los requisitos correspondientes, se procedió a efectuar el examen en los términos que establece el Reglamento de Estudios de Posgrado. Después de concluir la disertación y réplica de rigor, el jurado deliberó, habiéndose obtenido el siguiente resultado:

Aprobado

Para constancia se levantó la presente acta a las 17:30 horas del día 08 del mes de julio del año 2024, misma que suscriben los sinodales mencionados.

PRESIDENTE

Dr. Volodymyr Ponomaryov

SECRETARIO

Dra. Mariko Nakano

1er VOCAL

Dr. Alberto Jorge Rosales Silva

2º VOCAL

Dr. Dante Mújica Vargas

3er VOCAL

Dr. Francisco Javier Gallegos Funes

JEFE INTERINO DE LA SECCIÓN

M. en C. Osvaldo López García
Nombre y Firma

Secretaría de Investigación y Posgrado

LA SUSCRITA DIRECTORA DE LA ESCUELA SUPERIOR DE INGENIERÍA MECÁNICA Y ELÉCTRICA, UNIDAD CULHUACÁN

CERTIFICA que las firmas que anteceden son auténticas y corresponden a las personas cuyos nombres aparecen en esta acta.

Dra. Ana Lilia Coria Pérez
Nombre y Firma

M. en E. Dalia Ruiz Domínguez
Nombre y Firma

- Reporte Final del Periodo Sabático -