



EDUCACIÓN

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Tecnológico Nacional de México

Centro Nacional de Investigación
y Desarrollo Tecnológico

Tesis de Maestría

Implementación de Estrategias Avanzadas Utilizando
TOPSIS para la Selección Óptima de Trayectorias en
Vehículos Autoconducidos

presentada por

Ing. Andrés Antonio Arenas Muñiz

como requisito para la obtención del grado de
Maestro en Ciencias de la Computación

Director de tesis

Dr. Dante Mújica Vargas

Cuernavaca, Morelos, México. Mayo de 2024.



Cuernavaca, Mor., **23/abril/2024**

OFICIO No. DCC/043/2024
Asunto: Aceptación de documento de tesis
CENIDET-AC-004-M14-OFICIO

CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO
PRESENTE

Por este conducto, los integrantes de Comité Tutorial de **ANDRÉS ANTONIO ARENAS MUÑIZ** con número de control M22CE043, de la Maestría en Ciencias de la Computación, le informamos que hemos revisado el trabajo de tesis de grado titulado **"IMPLEMENTACIÓN DE ESTRATEGIAS AVANZADAS UTILIZANDO TOPSIS PARA LA SELECCIÓN ÓPTIMA DE TRAYECTORÍAS EN VEHÍCULOS AUTOCONDUCIDOS"** y hemos encontrado que se han atendido todas las observaciones que se le indicaron, por lo que hemos acordado aceptar el documento de tesis y le solicitamos la autorización de impresión definitiva.



NIMROD GONZÁLEZ FRANCO
Revisor 1



DANTE MÚJICA VARGAS
Director de tesis



NOÉ ALEJANDRO CASTRO SÁNCHEZ
Revisor 2

C.c.p. Depto. Servicios Escolares.
Expediente / Estudiante



Interior Internado Palmira S/N, Col. Palmira, C. P. 62490, Cuernavaca, Morelos
Tel. 01 (777) 3627770, ext. 3202, e-mail: dcc@cenidet.tecnm.mx | cenidet.tecnm.mx





Cuernavaca, Mor.,
No. De Oficio:
Asunto:

25/abril/2024
SAC/144/2024
Autorización de
impresión de tesis

**ANDRÉS ANTONIO ARENAS MUÑIZ
CANDIDATO AL GRADO DE MAESTRO
EN CIENCIAS DE LA COMPUTACIÓN
P R E S E N T E**

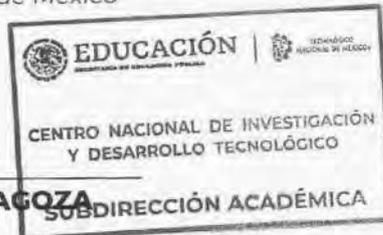
Por este conducto, tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado **"IMPLEMENTACIÓN DE ESTRATEGIAS AVANZADAS UTILIZANDO TOPSIS PARA LA SELECCIÓN ÓPTIMA DE TRAYECTORIAS EN VEHÍCULOS AUTOCONDUCIDOS"**, ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

A T E N T A M E N T E

*Excelencia en Educación Tecnológica®
"Conocimiento y tecnología al servicio de México"*

CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO



C. c. p. Departamento de Ciencias Computacionales
Departamento de Servicios Escolares

CMAZ/lmz



Dedicatoria

Dedico esta tesis
A mis padres, Antonio y Bertha
A mi hermano Angel
Y a mis abuelos

*Transmite lo que has aprendido,
constancia, dedicación;
pero insensatez,
debilidad, fracaso también.
¡Sí, fracaso sobre todo!
El mejor maestro, el fracaso es*

Agradecimientos

Agradezco al Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCYT) por el apoyo económico brindado durante mis estudios de maestría. Al Tecnológico Nacional de México / Centro Nacional de Investigación y Desarrollo Tecnológico CENIDET por brindar las instalaciones y permitirme realizar los estudios de maestría.

A mi director de tesis el Dr. Dante Mújica Vargas por su apoyo, consejo, dedicación y amistad brindada durante este proyecto de tesis. A mi comité revisor, el Dr. Noé Alejandro Castro Sánchez y Dr. Nimrod González Franco, por su asesoramiento para el desarrollo de esta investigación.

Extendido el agradecimiento al clan Nephilim y también a mis amigos, cuya amistad y respaldo han sido pilares fundamentales durante la realización de este proyecto. Valoro enormemente su compañía, llegando a considerarlos no solo amigos, sino también una extensión de mi propia familia.

¡Gracias!

Resumen

El estudio de la planificación y selección de trayectorias en vehículos autónomos, es crucial para su seguridad y eficiencia. Se destaca la importancia de considerar múltiples criterios, como velocidad, condiciones de la carretera y normas de tráfico. Aunque modelos de Aprendizaje Profundo han sido empleados con éxito, su alto costo computacional y necesidad de entrenamiento extenso plantean limitaciones. En esta investigación se propone un enfoque alternativo que prioriza la eficiencia y la flexibilidad en la toma de decisiones, sin requerir fases de entrenamiento extensas. El objetivo principal es desarrollar un esquema que integre algoritmos de bajo costo computacional y un método de toma de decisiones multi-criterio, con una componente difusa para incluir experiencia humana en el sistema. Los resultados obtenidos en los diferentes experimentos muestran que el sistema propuesto cumple con el objetivo principal de la investigación al obtener un desempeño favorable. De acuerdo a los experimentos llevados a cabo se demostró inicialmente que es posible alcanzar una configuración ideal de los vectores de impacto y peso mediante el ajuste fino. También se evidenció la factibilidad de dotar al sistema de la experiencia de conductores humanos, aunque esto implica adaptar un estilo de conducción específico, como se ilustra en los experimentos. Esta adaptación resulta crucial para lograr una conducción estable y segura. Al aumentar la dificultad de los escenarios mediante la variación de parámetros, se obtuvo evidencia que respalda la idea de que la aplicación de métodos de toma de decisiones puede conferir al sistema la flexibilidad necesaria para adaptarse a diversas situaciones.

Palabras clave: Vehículos autoconducidos, Planificación de trayectorias, Toma de decisiones, Múltiples criterios, Transferencia de experiencia, Situaciones adversas.

Abstract

Efficient and safe autonomous vehicles rely heavily on the study of path planning and selection. It is crucial to consider multiple criteria, including speed, road conditions, and traffic rules. While Deep Learning models have been successfully employed, their high computational cost and extensive training requirements pose limitations. The proposed approach prioritizes efficiency and flexibility in decision-making without requiring extensive training phases. Our objective is to develop a scheme that integrates low computational cost algorithms and a multi-criteria decision-making method with a fuzzy component to include human experience in the system. This approach is confident in its ability to provide a comprehensive solution to the problem at hand. The experiments demonstrate that the proposed system achieves the main objective of the research by performing favorably. The optimal configuration of the impact and weight vectors was achieved through fine-tuning. The experiments demonstrate that it is feasible to endow the system with the experience of human drivers. Adapting a specific driving style is crucial for achieving stable and safe driving. By increasing the difficulty of the scenarios by varying the parameters, evidence was obtained to support the idea that the application of decision-making methods can give the system the flexibility to adapt to different situations.

Keywords: Self-driving vehicles, Trajectory planning, Decision-making, Multiple criteria, Transfer of experience, Adverse situations..

Índice General

Lista de Figuras	xi
Lista de Tablas	xiii
1 Introducción	1
1.1 Planteamiento del problema	2
1.1.1 Delimitación del problema	2
1.1.2 Complejidad del problema	2
1.2 Objetivos	3
1.3 Alcances y limitaciones	3
1.4 Justificación	4
1.5 Organización de la tesis	4
2 Marco Teórico	5
2.1 Sistemas de referencia	5
2.2 Algoritmos para planificación de trayectorias	7
2.3 Selección de trayectorias	12
2.4 Seguimiento de trayectorias	14
3 Estado del Arte	17
3.1 Antecedentes	17
3.2 Trabajos relacionados	20
3.3 Toma de decisiones	27
3.4 Discusión del estado del arte	36
4 Metodología de Solución	40
4.1 Propuesta de solución	40
4.1.1 Módulo de percepción	41
4.1.2 Módulo de planificación de trayectorias	41
4.1.3 Módulo de selección de trayectorias	42
4.1.4 Módulo de control del vehículo	43
5 Experimentación y Resultados	44
5.1 Diseño Experimental	44

5.2	Entorno de desarrollo	44
5.3	Escenario de conducción	45
5.4	Métricas	45
5.5	Experimentos	47
5.5.1	Experimentación con el ajuste fino de los vectores de peso e impacto	48
5.5.2	Experimentación en un escenario con la presencia de obstáculos estáticos	50
5.5.3	Experimentación en un escenario con la presencia de obstáculos dinámicos	52
5.5.4	Experimentación con la inclusión de criterios adicionales	54
5.5.5	Experimentación con transferencia de experiencia	57
5.5.6	Experimentación variando los parámetros de la simulación	60
5.5.7	Experimentación variando los parámetros con obstáculos estáticos	62
5.5.8	Experimentación variando los parámetros con obstáculos dinámicos	63
5.5.9	Comparativa con otros métodos del estado del arte	64
5.5.10	Evaluación del tiempo de respuesta	67
6	Conclusiones	69
6.1	Objetivos y alcances logrados	69
6.2	Resultados del trabajo	71
6.2.1	Productos	71
6.3	Conclusiones	72
6.4	Trabajo futuro	73
	Referencias	74
	Apéndice A Encuesta	78
	Apéndice B Producción	79
	Apéndice C Retribución social	83

Lista de Figuras

2.1	Sistema de referencia cartesiano [38].	6
2.2	Triedro de Frenet sobre una curva.	6
2.3	Comparativa entre los dos sistemas de referencia [34].	7
2.4	Trayectoria circular [17].	8
2.5	Proceso de la toma de decisiones con múltiples criterios [7].	12
2.6	Relación geométrica de <i>Stanley</i>	15
3.1	Trayectoria generada por el algoritmo Theta* [37].	17
3.2	Funcionamiento del sistema propuesto [36].	18
3.3	Conducción del vehículo con la presencia de obstáculos [26].	18
3.4	Trayectorias generadas con la presencia de obstáculos [46].	19
3.5	Metodología de la propuesta de solución [4].	19
3.6	Optimización de rutas con el algoritmo HFS-A* [52].	20
3.7	Creación de línea de referencia a partir de una imagen de la carretera [29].	21
3.8	Ruta trazada por el algoritmo SAPSA [51].	22
3.9	Diagrama del sistema difuso propuesto [20].	23
3.10	Diagrama de la composición de la trayectoria [58].	23
3.11	Diagrama del método propuesto [24].	24
3.12	Diagrama de los diferentes bloques que integran la propuesta [16].	24
3.13	Diagrama de flujo del método propuesto [5].	25
3.14	Trayectorias generadas por el método propuesto [28].	25
3.15	Comparativa de las diferentes trayectorias generadas [30].	26
3.16	Trayectoria generada con la unión de clotoides y segmentos rectos [14]. .	26
3.17	Diagrama de la red convolucional [25].	27
3.18	Diagrama del entrenamiento de políticas [6].	28
3.19	Diagrama del método propuesto [48].	28
3.20	Diagrama de flujo del método propuesto [47].	29
3.21	Diagrama de la interacción entre las diferentes capas del modelo propuesto [49].	29
3.22	Diagrama del modelo propuesto [10].	30
3.23	Interacción entre la toma de decisiones y la planificación y control [15]. .	31
3.24	Diagrama los puntos críticos en las intersecciones [40].	31
3.25	Diagrama del modelo propuesto [9].	32

3.26	Arquitectura del modelo propuesto [31].	33
3.27	Interacción entre los elementos participantes en el sistema [32].	33
3.28	Diagrama del modelo propuesto [54].	34
3.29	Proceso de toma de decisiones [2].	34
3.30	Vehículos interactuando en una carretera [45].	35
3.31	Escenario para los experimentos [50].	36
4.1	Diagrama de la propuesta de solución.	40
4.2	Diagrama del módulo de percepción.	41
4.3	Diagrama del módulo de generación de trayectorias.	42
4.4	Diagrama del módulo de selección de trayectorias.	43
4.5	Diagrama del módulo de control del vehículo.	43
5.1	Escenario diseñado para los experimentos.	45
5.2	Resultados en las métricas para las combinaciones contempladas.	49
5.3	Resultados en las métricas con obstáculos estáticos.	51
5.4	Resultados en las métricas con obstáculos dinámicos.	53
5.5	Resultados en las métricas contemplando nuevos criterios.	56
5.6	Resultados en las métricas para los vectores obtenidos de los conductores.	59
5.7	Resultados para los diferentes límites de velocidad.	61
5.8	Resultados con la presencia de obstáculos estáticos.	62
5.9	Resultados con la presencia de obstáculos dinámicos.	63
5.10	Desempeño de los modelos con obstáculos estáticos.	65
5.11	Desempeño de los modelos con obstáculos dinámicos.	66
A.1	Fragmento de la encuesta realizada sobre las preferencias de conducción.	78
B.1	Constancia de la presentación del póster.	79
B.2	Constancia de ponencia.	80
B.3	Primera página del capítulo de libro.	81
B.4	Portada del artículo JCR.	82
C.1	Constancia de la presentación del póster.	83
C.2	Constancia de ponencia.	84
C.3	Primera página del capítulo de libro.	85
C.4	Primera página del artículo JCR.	86

Lista de Tablas

3.1	Resumen del estado del arte, planificación de trayectorias.	37
3.2	Resumen del estado del arte, toma de decisiones.	38
5.1	Resultados para el ajuste fino de los vectores W e I	48
5.2	Resultados obtenidos con la presencia de obstáculos estáticos	50
5.3	Resultados obtenidos con la presencia de obstáculos dinámicos	52
5.4	Resultados para las duplas considerando los nuevos criterios	55
5.5	Resultados de los vectores generados con la experiencia de conductores. .	57
5.6	Valores de los vectores W e I para cada estilo de conducción	60
5.7	Tiempos de respuesta para cada modelo en diferentes condiciones.	68
6.1	Objetivos específicos.	69
6.2	Alcances y Limitaciones.	70

Capítulo 1

Introducción

El propósito fundamental de un vehículo autónomo es alcanzar su destino, desplazándose desde el punto A hasta el punto B de la manera más segura y eficiente posible. Esta tarea implica la realización de diversas acciones, siendo la planificación de la trayectoria la más crucial. Dicha planificación se encarga de generar diversas trayectorias posibles que el vehículo podría seguir, con el objetivo de evitar colisiones y mantenerse en el carril. La elección de la trayectoria más apropiada se convierte en una tarea crítica, especialmente dada la diversidad de opciones generadas.

Para tomar decisiones informadas sobre la selección de la trayectoria, es esencial tener en cuenta una variedad de criterios. Entre ellos, se destacan la velocidad del vehículo, las condiciones de la carretera, la aceleración, la distancia de frenado y el mantenimiento del carril. Además, la trayectoria deseada debe cumplir con las normas de tráfico, garantizando el respeto de las regulaciones viales, sin comprometer el margen de seguridad y evitando posibles obstáculos. Esta complejidad demuestra que el número de criterios a considerar puede ampliarse para obtener una decisión más integral y fundamentada.

Dentro de la literatura, las tareas de la planificación y selección de trayectorias se realizan mediante modelos del Aprendizaje Profundo y Aprendizaje Profundo Reforzado respectivamente. Si bien estas propuestas han alcanzado buenos resultados, tienen un gran inconveniente, el cual es su elevado costo computacional y la necesidad de una etapa de entrenamiento con grandes cantidades de datos, y al igual que con otras arquitecturas pueden caer en problemas de mínimos locales o sobre entrenamiento.

Por lo cual se consideró abordar otro tipo de técnicas para realizar estas tareas que no tengan un alto costo computacional, ni requieran de fases de entrenamiento, a su vez se buscó dotar al esquema propuesto de flexibilidad a la hora de tomar decisiones con el objetivo de hacerlo más tolerante a situaciones adversas e incertidumbre.

Por tanto, el objetivo principal de esta investigación fue el desarrollar un esquema para la planificación y selección de trayectorias utilizando algoritmos de bajo costo computacional y un método de toma de decisiones con múltiples criterios, el cual deber de integrar una componente difusa en el sentido de contar con un método de inferencia que permita la inclusión de experiencia humana en el sistema.

1.1 Planteamiento del problema

Los vehículos autoconducidos son una aplicación de la Robótica Móvil, utilizan diferentes métodos para la planificación de las trayectorias, entre los que destacan el trazado por polinomios de cuarto y quinto orden, los cuales generar una gama de trayectorias que posteriormente debe evaluarse para seleccionar la adecuada según sea la situación. Los métodos convencionales, como las funciones de pérdida o la medición del error, no cuentan con un proceso para determinar si efectivamente la trayectoria generada es la más adecuada para la situación. Debido a que evalúan las trayectorias desde valores fijos límites que estas no deben rebasar, estos métodos son débiles ante situaciones adversas que pueden presentarse en el entorno de la conducción, que pueden obligar al vehículo a sobrepasar estas limitantes para evitar una colisión.

Hipótesis: Al optar por un método de toma de decisiones con múltiples criterios, se aumentará la capacidad de evaluar las trayectorias generadas y se será más robusto ante situaciones adversas.

1.1.1 Delimitación del problema

Dentro de este trabajo de investigación se desarrolló un método para el trazado y selección de las trayectorias óptimas para un vehículo autónomo. Se contempló utilizar el espacio de Frenet para generar las trayectorias mediante los algoritmos polinomiales. Se seleccionó la trayectoria que mejor se apegó a las condiciones mediante un método de toma de decisiones con múltiples criterios.

1.1.2 Complejidad del problema

La complejidad del problema radica en lo tratado en los siguientes puntos:

1. Trazar las trayectorias con los parámetros iniciales, objetivo y contemplando los obstáculos y curva de referencia dentro del espacio de Frenet.
2. Seleccionar la trayectoria adecuada a través de métodos del estado del arte que permitan contemplar varios criterios.
3. Realizar el seguimiento de la trayectoria seleccionada.

1.2 Objetivos

Objetivo general

Desarrollar un método para la planificación y selección de la trayectoria óptima, con el fin de prevenir accidentes vehiculares.

Objetivos específicos

- Programar un planificador de trayectorias locales considerando el espacio de Frenet.
- Desarrollar un método para seleccionar la trayectoria adecuada.
- Efectuar experimentos contemplando maniobras longitudinales y laterales, con el objetivo principal de evitar accidentes viales.
- Evaluar el desempeño del método propuesto.

1.3 Alcances y limitaciones

Alcances

- Se contemplarán entornos controlados que representen vías rectas y curvas.
- Se contemplarán obstáculos estáticos.
- Se realizará el trazado y selección de las trayectorias.
- Las pruebas se efectuarán a nivel de simulación.
- Se experimentará con el método propuesto de selección de trayectorias.
- Se contemplará el seguimiento de la trayectoria seleccionada.
- El método de toma de decisiones contemplará 4 criterios: velocidad, aceleración, ángulo de giro y colisiones.

Limitaciones

- El método propuesto no contemplará la percepción ni el control del vehículo.
- Los obstáculos, ancho de vía y curva de referencia deben ser proporcionados por el sistema de percepción del vehículo.

- No se contempla su funcionamiento en vías urbanas.
- El modelo dinámico del vehículo, así como otras condiciones ambientales, no serán contempladas.

1.4 Justificación

La industria automotriz ha entrado en un período de transformación que tendrá una evolución sin precedentes en las capacidades tecnológicas de los vehículos. Los avances en nuevas técnicas de fabricación, sensores de bajo costo, alto poder de procesamiento computacional, acceso en tiempo real a la información y la inclusión de la inteligencia computacional, han hecho que los vehículos estén cambiando rápidamente y creciendo en complejidad. Estas nuevas tecnologías permitirán la inevitable evolución hacia los vehículos autónomos, aunque de manera inmediata brindarán beneficios sustanciales a los conductores, los pasajeros y el medio ambiente.

Para ponerse en contexto con los procesos que un sistema de conducción autónoma requiere para la evasión de obstáculos, se deben considerar cuatro tareas básicas: a) la percepción del entorno, b) el conocimiento de la posición del vehículo y obstáculos cercanos, c) la planificación/generación de trayectorias, y d) el control del vehículo para realizar el seguimiento de la mejor trayectoria.

El presente trabajo de investigación está centrado en el desarrollo de un método que permita seleccionar la trayectoria óptima, tomando en cuenta diferentes criterios

1.5 Organización de la tesis

Este documento de tesis esta compuesto por cinco capítulos principales, además de los anexos y referencias. El Capítulo 2 contiene el marco conceptual, dentro de este se encontrarán los conceptos teóricos básicos como los sistemas de referencia, referencia móvil de Frenet, algoritmos de trazado de trayectorias y métodos para selección de trayectorias, técnicas de toma de decisiones con múltiples criterios y la técnica TOPSIS, que fueron necesarios para comprender y desarrollar esta investigación. En el Capítulo 3 se realiza una revisión del estado del arte contemplando principalmente dos núcleos temáticos: la planificación de trayectorias y la toma de decisiones aplicada al contexto de la conducción autónoma. Dentro del Capítulo 4 se detalla la formalización matemática y acondicionamiento del método desarrollado para la planificación y selección de trayectorias. El Capítulo 5 detalla la experimentación realizada y los resultados obtenidos. Por último el Capítulo 6 se presentan las conclusiones de la investigación, trabajo futuro y productos obtenidos.

Capítulo 2

Marco Teórico

En este capítulo se describen los conceptos teóricos básicos como lo son: los sistemas de referencia, la referencia móvil de Frenet, los algoritmos de trazado de trayectorias y métodos para selección de trayectorias, que son necesarios para comprender y desarrollar el tema de investigación propuesto.

2.1 Sistemas de referencia

La descripción precisa de la posición en el espacio de un objeto se realiza con la ayuda de un sistema de coordenadas, usualmente del tipo euclidiano, el cual provee los elementos necesarios para describir la posición de un objeto en el espacio, estos elementos son los siguientes [38]:

- Sistema de coordenadas.
- Ejes perpendiculares.
- Origen.
- Temporizador para asignar un tiempo a cada posición.

El sistema de referencia más utilizado es el cartesiano, dado que la posición del objeto se determina por las coordenadas x, y, z a lo largo de tres ejes perpendiculares, cuenta con un observador u origen y ejes para describir las posiciones en el sistema. En la Figura 2.1 se puede observar el sistema de coordenadas cartesiano.

Los ejes x, y, z son perpendiculares entre si, interceptándose en el punto o al cual se le denomina origen, la posición del punto P se puede determinar con las coordenadas $(x, y, z) = (3, 2, 3)$.

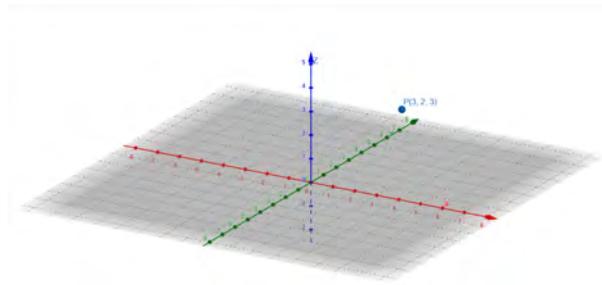


Figura 2.1 Sistema de referencia cartesiano [38].

Referencia móvil de Frenet

La geometría diferencial de curvas se emplea para analizar una curva en el espacio euclidiano, mediante una curva paramétrica, la cual permite representar la trayectoria de cualquier objeto moviéndose por el espacio mediante la descripción del cambio de posición en cada uno de los ejes a través del tiempo t . Para una partícula física desplazándose en el espacio, el vector tangente es paralelo a la velocidad, mientras que el vector normal indica el cambio dirección por unidad de tiempo de la velocidad o aceleración normal.

La referencia móvil de Frenet o triedro de Frenet, que se ilustra en la Figura 2.2, es un sistema de referencia ortonormal. Creado a partir de una curva paramétrica $\gamma(t)$ definida en un espacio \mathbb{R}^2 , la cual es observada en un intervalo de tiempo I donde a partir de la primera y segunda derivada se construyen los vectores **tangente** T y **normal principal** N que corresponden a los ejes perpendiculares, con estos ejes se crea el sistema de coordenadas [43]. Decimos que es un sistema de referencia móvil, porque se desplaza por la curva conforme se avanza en el tiempo.

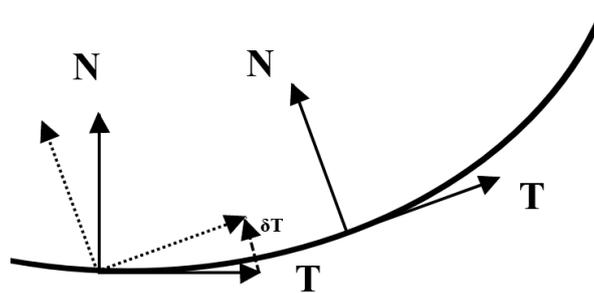


Figura 2.2 Triedro de Frenet sobre una curva.

Para la creación de este sistema de referencia se parte de una curva paramétrica como la de la siguiente expresión [43]:

$$\gamma(t) = (f(t)x + g(t)y + h(t)z) \quad (2.1)$$

donde $\gamma(t)$ es la expresión de la curva paramétrica, $f(t)x$ 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 . A partir $\gamma(t)$ de la cual se pueden definir los vectores tangente y normal principal, como se muestra en las siguientes expresiones:

$$T = \frac{\gamma'(t)}{\|\gamma'(t)\|_2} \quad (2.2)$$

$\gamma'(t)$ es la primera derivada y $\|\gamma'(t)\|_2$ es la norma euclidiana.

$$N = \frac{T'(t)}{\|T'(t)\|_2} \quad (2.3)$$

En la Figura 2.3 se puede apreciar la diferencia entre los sistemas cartesiano y de Frenet.

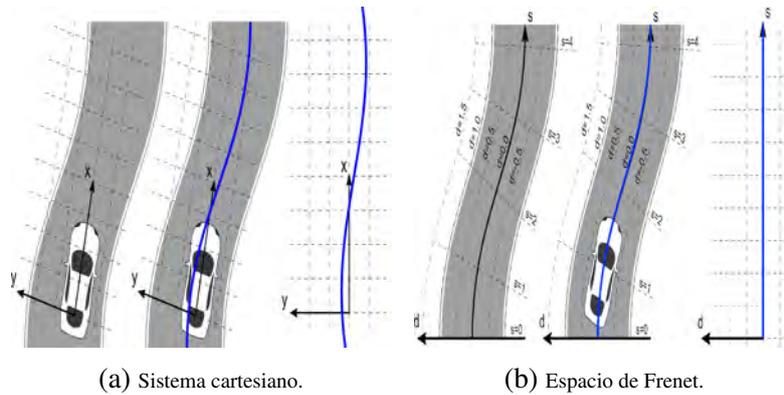


Figura 2.3 Comparativa entre los dos sistemas de referencia [34].

Para este trabajo de investigación resultó de utilidad trabajar con una referencia móvil debido a que permite incluir en el sistema de coordenadas a la geometría del camino, con lo cual la localización de los vehículos y obstáculos se hace con referencia a la propia carretera, como se puede observar en la Figura 2.3.

2.2 Algoritmos para planificación de trayectorias

Un algoritmo de planificación de trayectorias se encarga de encontrar el camino óptimo entre dos puntos, contempla los parámetros geométricos del camino, la posición y trayectoria de otros vehículos, así como las limitaciones del vehículo para calcular una trayectoria que pueda evadir una colisión [17].

Existen diferentes acercamientos para el trazado de estas trayectorias, pero todos contemplan los siguientes parámetros:

- Tiempo de transición.
- Máxima aceleración lateral.
- Velocidad del vehículo.

Partiendo de la geometría del camino, el algoritmo entregará como producto trayectorias que pueden ser arcos o segmentos de los mismos, todos ellos crean puntos intermedios para poder seguir la trayectoria generada.

Algoritmo de trayectoria circular

El algoritmo más simple es del de trayectoria circular, el cual se representa por la siguiente expresión matemática [17]:

$$L_w = 2 \frac{V^2}{a_{max}} \left[1 - \cos\left(\frac{a_{max}t_c}{V}\right) \right] + Vt_s \operatorname{sen}\left(\frac{a_{max}t_c}{V}\right) \quad (2.4)$$

donde L_w representa el ancho del carril, V es la velocidad del vehículo, a_{max} es la aceleración máxima, t_c que corresponde la porción circular, generada con las funciones sen y cos , de ahí el nombre de trayectoria circular y t_s al segmento de recta que une las dos partes. La trayectoria generada por este algoritmo se puede apreciar en la Figura 2.4.

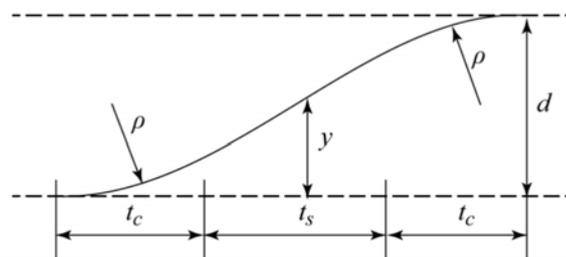


Figura 2.4 Trayectoria circular [17].

En la Figura 2.4 d corresponde al ancho total de la carretera, p es el ancho de carril que en la expresión 2.4 corresponde al parámetro L_w .

Aproximación sinusoidal

Partiendo de una forma sinusoidal se puede aproximar una trayectoria ajustando los parámetros de la curva sinusoidal, ésta se puede describir con la siguiente ecuación:

$$y(t) = \frac{L_w}{2} \left[1 + \operatorname{sen}\left(\alpha t - \frac{\pi}{2}\right) \right], \quad 0 \leq \alpha t \leq \pi. \quad (2.5)$$

donde α es la aceleración del vehículo, mientras que los demás parámetros son los mismos que para el algoritmo de trayectoria circular.

Algoritmo polinomial

Este algoritmo traza una trayectoria a partir de un punto inicial a un punto de destino definido por un conjunto de coordenadas como funciones de tiempo, velocidad y aceleración [17]. A partir de ciertos puntos y las limitantes del vehículo puede trazar una trayectoria suavizada utilizando una aproximación cúbica o de quinto orden con coeficientes independientes. La trayectoria entre dos puntos se define por la siguiente expresión:

$$Y(t) = a_0 + a_1t + a_2t^2 + a_3t^3 \quad (2.6)$$

donde $Y(t)$ es la función que describe la trayectoria y los coeficientes a_0 , a_1 , a_2 y a_3 son determinados por las características del camino. La velocidad y aceleración se calcula a partir de la primera y segunda derivada de la expresión 2.6:

$$Y'(t) = v(t) = a_1 + 2a_2t + 3a_3t^2 \quad (2.7)$$

$$Y''(t) = \alpha(t) = 2a_2 + 6a_3t \quad (2.8)$$

donde $Y'(t)$ es la velocidad del vehículo $v(t)$ y $Y''(t)$ la aceleración $\alpha(t)$. Los coeficientes son determinados por las características del camino y las limitantes del vehículo en un tiempo inicial t_0 y un tiempo final t_f . Los coeficientes de las ecuaciones anteriores se puede resolver con la siguiente matriz:

$$\begin{bmatrix} 1 & t_0 & t_0^2 & t_0^3 \\ 0 & 1 & 2t_0 & 3t_0^2 \\ 1 & t_f & t_f^2 & t_f^3 \\ 0 & 1 & 2t_f & 3t_f^2 \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \\ a_2 \\ a_3 \end{bmatrix} = \begin{bmatrix} Y_0 \\ V_0 \\ Y_f \\ V_f \end{bmatrix} \quad (2.9)$$

donde Y_0 y Y_f son las posiciones iniciales y finales, mientras que V_0 y V_f son las velocidades inicial y final, respectivamente [17]. Una versión optimizada de este algoritmo es el polinomial de quinto orden, el cual se expresa en la siguientes ecuaciones, en conjunto con su primera y segunda derivada respectivamente:

$$Y(t) = a_0 + a_1t + a_2t^2 + a_3t^3 + a_4t^4 + a_5t^5 \quad (2.10)$$

$$Y'(t) = v(t) = a_1 + 2a_2t + 3a_3t^2 + 4a_4t^3 + 5a_5t^4 \quad (2.11)$$

$$Y''(t) = \alpha(t) = 2a_2 + 6a_3t + 12a_4t^2 + 20a_5t^3 \quad (2.12)$$

Por lo tanto, las limitantes se pueden expresar de la misma forma mediante una matriz:

$$\begin{bmatrix} 1 & t_0 & t_0^2 & t_0^3 & t_0^4 & t_0^5 \\ 0 & 1 & 2t_0 & 3t_0^2 & 4t_0^3 & 5t_0^4 \\ 0 & 0 & 2 & 6t_0 & 12t_0^2 & 20t_0^3 \\ 0 & t_f & t_f^2 & t_f^3 & t_f^4 & t_f^5 \\ 0 & 1 & 2t_f & 3t_f^2 & 4t_f^3 & 5t_f^4 \\ 0 & 0 & 2 & 6t_f & 12t_f^2 & 20t_f^3 \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \\ a_2 \\ a_3 \\ a_4 \\ a_5 \end{bmatrix} = \begin{bmatrix} Y_0 \\ V_0 \\ A_0 \\ Y_f \\ V_f \\ A_f \end{bmatrix} \quad (2.13)$$

En este punto se estima el ángulo de giro α . El primer paso es eliminar el error entre el curso actual y el curso deseado mediante la siguiente expresión:

$$\delta(t) = \Psi(t) \quad (2.14)$$

Después se eliminará el error de cruce de vía encontrando el punto más cercano entre la trayectoria trazada y el centro del eje frontal del vehículo denotado por $e(t)$ en la siguiente expresión [13]:

$$\delta(t) = \tan^{-1}\left(\frac{Ke(t)}{V_f(t)}\right) \quad (2.15)$$

donde K es la ganancia y δ es el ángulo corregido del vehículo, pero este ángulo debe de acotarse entre los ángulos máximos de giro, lo que significa que $\delta(t) \in [\delta_{min}, \delta_{max}]$. Así se llegará a la siguiente expresión:

$$\delta(t) = \Psi(t) + \tan^{-1}\left(\frac{Ke(t)}{V_f(t)}\right), \delta(t) \in [\delta_{min}, \delta_{max}] \quad (2.16)$$

Se puede añadir otra ganancia k_s para suavizar el control y asegurar que el denominador no sea cero, tal como se muestra en la siguiente ecuación:

$$\delta(t) = \Psi(t) + \tan^{-1}\left(\frac{Ke(t)}{k_s + V_f(t)}\right) \quad (2.17)$$

En conjunto, el espacio de Frenet y los algoritmos polinomiales se pueden aplicar para generar las diferentes trayectorias, como se puede apreciar en el Pseudocódigo 1.

El algoritmo comienza calculando el vector tangente T a la curva en un punto dado t , dividiendo la derivada de la curva $\gamma'(t)$ por su norma euclidiana. Este vector tangente T se utiliza como el eje longitudinal del sistema de referencia. Luego, se calcula el vector normal principal N dividiendo la derivada de T por su norma euclidiana. N se convierte en el eje lateral del sistema de referencia.

Con estos vectores T y N , se crea un sistema de referencia en el espacio para describir la orientación del vehículo en cada punto de la trayectoria.

A continuación, se utilizan polinomios de quinto orden para calcular los desplazamientos lateral $d(t)$ y longitudinal $s(t)$ a lo largo de la trayectoria. Estos polinomios se definen por coeficientes d_0, d_1, \dots, d_5 y s_0, s_1, \dots, s_5 respectivamente. Estos desplazamientos son esenciales para determinar la posición exacta del vehículo en cada instante de tiempo a lo largo de la trayectoria.

El ángulo de giro α del vehículo se obtiene a partir de una función $\sigma(t)$, que probablemente esté relacionada con las características geométricas de la trayectoria y las restricciones de movimiento.

La velocidad v del vehículo se calcula como la primera derivada de la función de desplazamiento longitudinal $s(t)$, mientras que la aceleración a se calcula como la segunda derivada de la misma función. Estos valores son cruciales para controlar el movimiento del vehículo y garantizar una conducción segura y suave.

Finalmente, todos estos datos (desplazamientos lateral y longitudinal, ángulo de giro, velocidad y aceleración) se agrupan en una matriz δ para cada punto de la trayectoria, lo que proporciona una descripción completa del movimiento del vehículo a lo largo del camino deseado. Este proceso se repite para cada punto de la trayectoria, generando así una trayectoria continua y bien definida para el vehículo. Este proceso se puede resumir en el Pseudocódigo 1.

Algoritmo 1 Generación de trayectorias con la referencia de Frenet.

Require: $\varpi(t)$ Curva paramétrica del camino, $[\psi_0^1, \psi_0^2, \dots, \psi_0^n]$ Estados iniciales, $[\psi_f^1, \psi_f^2, \dots, \psi_f^n]$ Estados objetivo.

Ensure: $\delta = [d, s, \alpha, v, a]$ ▷ Matriz de puntos de la trayectoria generada.

$T \leftarrow \frac{\gamma'(t)}{\|\gamma'(t)\|_2}$ ▷ Vector tangente.

$N \leftarrow \frac{T'(t)}{\|T'(t)\|_2}$ ▷ Vector normal principal.

Creación del sistema de referencia con los vectores T y N .

$d(t) = d_0 + d_1t + d_2t^2 + d_3t^3 + d_4t^4 + d_5t^5$ ▷ Puntos de desplazamiento lateral.
 $s(t) = s_0 + s_1t + s_2t^2 + s_3t^3 + s_4t^4 + s_5t^5$ ▷ Puntos de desplazamiento longitudinal.

$\alpha \leftarrow \sigma(t)$ ▷ Ángulo de giro.

$v \leftarrow s'(t)$ ▷ Velocidad.

$a \leftarrow s''(t)$ ▷ Aceleración.

$\delta = [d, s, \alpha, v, a]$ ▷ Matriz para cada trayectoria.

2.3 Selección de trayectorias

Generado el conjunto de trayectorias es necesario contar con un método para poder seleccionar la trayectoria adecuada para la situación en la que se encuentra el vehículo, para esto resulta ideal contemplar varios criterios, lo cual permite tomar una decisión más informada.

El proceso de toma de decisiones con múltiples criterios consta de ciertos pasos, los cuales se pueden apreciar en el diagrama de la Figura 2.5.



Figura 2.5 Proceso de la toma de decisiones con múltiples criterios [7].

La selección de criterios es de vital importancia, ya que estos dirigirán la evaluación de las opciones disponibles y la selección de la mejor alternativa. Algunos criterios pueden ser más importantes que otros para el problema en cuestión, por lo que se pueden asignar pesos o impacto a cada uno de ellos para reflejar su importancia en la decisión.

La Técnica para Orden de Preferencia por Semejanza a la Solución Ideal (TOPSIS) [7] evalúa las trayectorias generadas respecto a una solución ideal determinada por un *mejor ideal* o *peor ideal* ajustado por la experiencia de un conductor humano. Por lo tanto, este método permite transmitir de cierta forma la experiencia humana para realizar una toma de decisiones.

Éste requiere de una matriz Γ que contiene los candidatos, el vector de peso W y el vector de impacto I , donde el vector $W = [w_1, \dots, w_n]$ contiene el peso para cada columna de la matriz Γ , que puede ser cualquier valor entre $[1, \infty]$, y el vector $I = [i_1, \dots, i_n]$ contiene el impacto que es un indicador de la preferencia para que el algoritmo TOPSIS estimule el aumento o disminución de los valores de las respectivas columnas.

El primer paso del algoritmo TOPSIS es la normalización de la matriz Γ con la siguiente expresión:

$$\mathbf{N}_\Gamma = \|\Gamma_{ij}\|_2 = \frac{\Gamma_{ij}}{\sqrt{\sum_{i=1}^n \sum_{j=j}^n (x_{ij})^2}} \quad (2.18)$$

donde x_{ij} representa a cada elemento de la matriz Γ , a los cuales se les aplica la norma euclidiana como se muestra en la ecuación 2.18, con la normalización los valores de la matriz se trasladan al dominio difuso de $[0, 1]$. Después se aplica el peso, a través del vector W_j , a todos los elementos de la matriz normalizada \mathbf{N}_Γ , como se muestra en la siguiente expresión:

$$\mathbf{W}_{rij} = \mathbf{N}_{\Gamma_{ij}} * W_j \quad (2.19)$$

A partir de este punto es posible determinar el mejor ideal \mathbf{I}_B y el peor ideal \mathbf{I}_W para cada columna. Con la referencia de los vectores de impacto y peso, el impacto deseado se representa mediante los signos $[+, -]$, que indican el incremento o disminución deseado para cada parámetro, los vectores \mathbf{I}_B y \mathbf{I}_W se obtienen mediante las siguientes expresiones:

$$\mathbf{I}_{B_j} = \max(\mathbf{W}_{\Gamma_j}) \quad \mathbf{I}_{W_j} = \min(\mathbf{W}_{\Gamma_j}) \quad (2.20)$$

El siguiente paso corresponde a la aplicación de la distancia euclidiana entre los candidatos y los vectores \mathbf{I}_B y \mathbf{I}_W para cada columna, lo cual generara la distancia positiva \mathbf{P}_d y la distancia negativa \mathbf{N}_d con las siguientes expresiones a partir de los elementos de la matriz \mathbf{N}_Γ :

$$\mathbf{P}_d = \sqrt{\sum_{i=1}^n (\mathbf{I}_{B_j} - \mathbf{P}_{\Gamma_{ij}})^2} \quad \mathbf{N}_d = \sqrt{\sum_{i=1}^n (\mathbf{I}_{W_j} - \mathbf{N}_{\Gamma_{ij}})^2} \quad (2.21)$$

La puntuación para cada candidato o *Score* para cada fila de la matriz \mathbf{N}_Γ se obtiene mediante la siguiente expresión:

$$Score = \mathbf{N}_d / (\mathbf{N}_d + \mathbf{P}_d) \quad (2.22)$$

El proceso descrito anteriormente se detalla en el Pseudocódigo 2:

Algoritmo 2 TOPSIS aplicado para la evaluación de candidatos

Require: Γ_{ij} Conjunto de trayectorias, $W_j = [w_1, \dots, w_n]$ Vector de pesos, $I_j = [i_1, \dots, i_n]$ Vector de impacto.

Ensure: *Score* Valor entre $[0, 1]$ que denota el puntaje.

$$N_{\Gamma_{ij}} = \|\Gamma_{ij}\|_2 = \frac{\Gamma_{ij}}{\sqrt{\sum_{i=1}^n \sum_{j=1}^n (x_{ij})^2}} \quad \triangleright \text{Normalización de la matriz de candidatos.}$$

for i in N_{Γ_i} **do**
 for j in W_j **do**
 $\mathbf{W}_{\Gamma_{ij}} \leftarrow N_{\Gamma_{ij}} \times W_j$ \triangleright Aplicación del peso a la matriz de candidatos normalizada.
 if $i_j == '+'$ **then** \triangleright Para el incremento de los valores de una columna.
 $\mathbf{I}_{B_j} = \max(\mathbf{W}_{\Gamma_j}) \mathbf{I}_{B_j}$ \triangleright Cálculo del mejor ideal.
 $\mathbf{I}_{W_j} = \min(\mathbf{W}_{\Gamma_j}) \mathbf{I}_{W_j}$ \triangleright Cálculo del peor ideal.
 else $i_j == '-'$ **then** \triangleright Para la reducción de los valores de cierta característica.
 $\mathbf{I}_{W_j} = \max(\mathbf{W}_{\Gamma_j})$
 $\mathbf{I}_{B_j} = \min(\mathbf{W}_{\Gamma_j})$
 end if
 end for
end for
 $\mathbf{p}_d \leftarrow \sqrt{\sum_{i=1}^n (\mathbf{I}_{B_j} - \mathbf{W}_{\Gamma_{ij}})^2}$ \triangleright Cálculo de la distancia positiva euclidiana entre los candidatos y el mejor ideal.
 $\mathbf{n}_d \leftarrow \sqrt{\sum_{i=1}^n (\mathbf{I}_{W_j} - \mathbf{W}_{\Gamma_{ij}})^2}$ \triangleright Cálculo de la distancia negativa euclidiana entre los candidatos y el peor ideal.
 $\text{Score} \leftarrow \frac{\mathbf{n}_d}{\mathbf{n}_d + \mathbf{p}_d}$ \triangleright Obtención del puntaje para cada trayectoria.

2.4 Seguimiento de trayectorias

Una vez que se ha seleccionado la trayectoria adecuada, se debe de contar con un método para que el vehículo siga y mantenga esta trayectoria.

Modelo de control *Stanley*

Una forma de realizar el seguimiento es mediante una comparación entre la trayectoria y el ángulo de orientación del vehículo. Se puede calcular el error entre estos y efectuar los ajustes correspondientes en dirección. En la Figura 2.6 se puede observar un diagrama en el que se representa la relación entre la trayectoria y el eje frontal del vehículo [41].

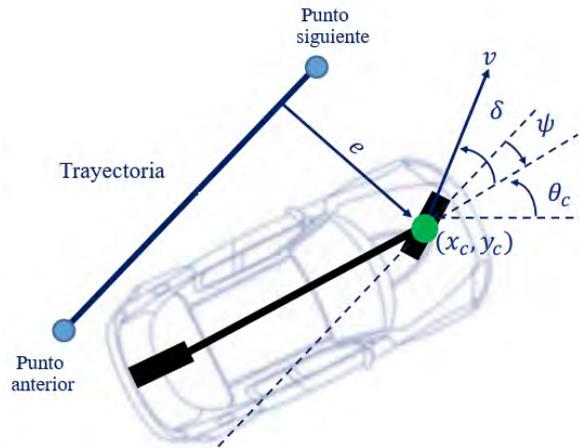


Figura 2.6 Relación geométrica de Stanley.

Para efectuar un ajuste lateral se asume que la velocidad se mantiene constante para simplificar los cálculos. En la Figura 2.6 δ representa el ángulo del curso actual del vehículo, Ψ es el ángulo que debe tener el automóvil, V_f es el ángulo de la dirección, e es la distancia del eje frontal a la trayectoria y L es la distancia entre ejes del vehículo.

El primer paso es eliminar el error entre el curso actual y el curso deseado mediante la siguiente expresión:

$$\delta(t) = \Psi(t) \quad (2.23)$$

Después se eliminará el error de cruce de vía encontrando el punto más cercano entre la trayectoria trazada y el centro del eje frontal del vehículo denotado por $e(t)$ en la siguiente expresión [13]:

$$\delta(t) = \tan^{-1}\left(\frac{Ke(t)}{V_f(t)}\right) \quad (2.24)$$

donde K es la ganancia y δ es el ángulo corregido del vehículo, pero este ángulo debe de acotarse entre los ángulos máximos de giro, lo que significa que $\delta(t) \in [\delta_{min}, \delta_{max}]$. Así se llegará a la siguiente expresión:

$$\delta(t) = \Psi(t) + \tan^{-1}\left(\frac{Ke(t)}{V_f(t)}\right), \delta(t) \in [\delta_{min}, \delta_{max}] \quad (2.25)$$

Se puede añadir otra ganancia k_s para suavizar el control y asegurar que el denominador no sea cero, tal como se muestra en la siguiente ecuación:

$$\delta(t) = \Psi(t) + \tan^{-1}\left(\frac{Ke(t)}{k_s + V_f(t)}\right) \quad (2.26)$$

Para el caso de la velocidad se puede realizar un seguimiento utilizando el método de Stanley en el cual se compara el valor de velocidad de referencia proporcionado por la trayectoria. Se busca que la velocidad se apege a los límites indicados por las autoridades, así como a los calculados para ejecutar las diferentes maniobras. El controlador emplea

la mínima de las velocidades antes mencionadas como referencia, además considera al acelerador y freno como dos actuadores opuestos que ejercen una fuerza longitudinal en el vehículo.

El modelo recibe la velocidad de referencia e_v , a partir de la cual se calcula sólo el error, en una interacción discreta $i + 1$ [13],

$$e_v(i+1) = k_{p,v}(v(i+1) - v_c(i+1)) + k_{i,v}e_{int}(i+1) \quad (2.27)$$

donde el término integral se define como:

$$e_{int}(i+1) = e_{int}(i) + (v(i) - v_c(i)) \quad (2.28)$$

donde v_c es la velocidad que se requiere, los valores $k_{p,v}$ y $k_{i,v}$ determinan el intercambio entre el rechazo a las perturbaciones y rebasar la velocidad objetivo. Cuando el error es positivo se acciona el freno de forma proporcional al error PI, cuando es negativo se ajusta proporcionalmente el acelerador del vehículo.

Discusión

Este capítulo presentó un panorama general sobre los temas relacionados con el trabajo de investigación que se desarrolla en este tema de tesis, abarcando los conceptos básicos respecto a los sistemas de referencias y el porque es necesario transitar a una referencia móvil, la generación de múltiples trayectorias y los métodos de toma de decisiones con múltiples criterios, en específico el método TOPSIS, así como el modelo de control del vehículo encargado de realizar el seguimiento de las trayectorias. Se describieron los conceptos implementados en la propuesta de solución con el objetivo de mejorar la comprensión del funcionamiento de la misma.

Capítulo 3

Estado del Arte

En esta sección se exponen de manera concisa las investigaciones previas relevantes al tema de la tesis, así como los estudios relacionados con la planificación y selección de trayectorias para vehículos autoconducidos.

3.1 Antecedentes

Algunas de las investigaciones que anteceden a la actual propuesta de tesis son:

Evaluación del algoritmo Theta* para planeación de trayectorias [37].

En este trabajo de investigación se propuso utilizar el algoritmo Theta* con el objetivo de crear rutas más cortas con un tiempo de ejecución aceptable. Se realizó la experimentación en el entorno *Robot Operating System* donde se comparó su contra los algoritmos Dijkstra y A*. Los resultados que se obtuvieron mostraron que el algoritmo Theta* generó las trayectorias y llegó a la meta en el 100% de los casos, mientras que los otros dos algoritmos obtuvieron resultados mucho menores. En la Figura 3.1 se observa una de las trayectorias generadas mediante el algoritmo Theta*.



Figura 3.1 Trayectoria generada por el algoritmo Theta* [37].

Sistema Embebido para Asistencia de Conducción Basado en Lógica Difusa Tipo-2 [36].

En este trabajo se presentó el desarrollo de un asistente de conducción basado en Lógica Difusa Tipo-2. Empleo visión por computadora para la detección de niveles de riesgo, contemplando la percepción de un vehículo al frente y la inatención al camino por parte del conductor. El sistema se implementó en una plataforma embebida *NVIDIA Jetson TX2*, la cual se equipó a bordo de un automóvil donde se efectuaron pruebas reales. Se obtuvo un rendimiento mayor a 0.90 con una implementación real operando a 24.63 cuadros por segundo. En la Figura 3.2 se puede observar la detección del rostro y los vehículos por parte del sistema.

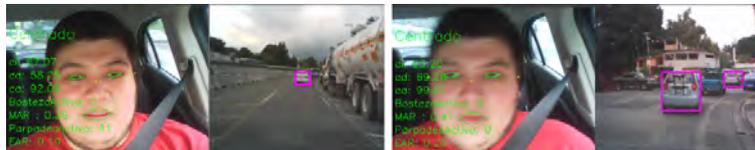


Figura 3.2 Funcionamiento del sistema propuesto [36].

Conducción Autónoma de un Vehículo Simulado mediante un Modelo de Red Neuronal Convolutiva Recurrente [26].

En esta investigación se propuso un método para la conducción autónoma de un vehículo a partir del procesamiento de secuencias de imágenes mediante una Red Neuronal Convolutiva Recurrente, con lo cual se obtuvieron los ángulos de la dirección del vehículo para ejecutar las diferentes maniobras según fuesen requeridas por el camino. Las imágenes contaron con un canal de profundidad, ya que se fusionaron datos de sensores visuales y espaciales. En la Figura 3.3 se observa la trayectoria generada por el sistema para evadir los obstáculos presentes en el camino.



Figura 3.3 Conducción del vehículo con la presencia de obstáculos [26].

Navegación de un robot omnidireccional basada en Lógica Difusa Tipo-2 [46].

En este trabajo se presentó el desarrollo de un sistema de navegación para un robot omnidireccional. Utilizo una cámara estero para generar un mapa de profundidad en el cual se calcularon las trayectorias para llegar a una meta. La Lógica Difusa Tipo-2 se empleó para determinar las velocidades lineales y angulares del robot. Este sistema de navegación se implementó en una plataforma embebida *NVIDIA Jetson TX2* con la cual se realizaron pruebas con obstáculos dinámicos y estáticos. Utilizó el *Probabilistic Random Map* como algoritmo de planificación de rutas. En la Figura 3.4 se muestran las trayectorias generadas por el robot para evadir los obstáculos y llegar a su destino.

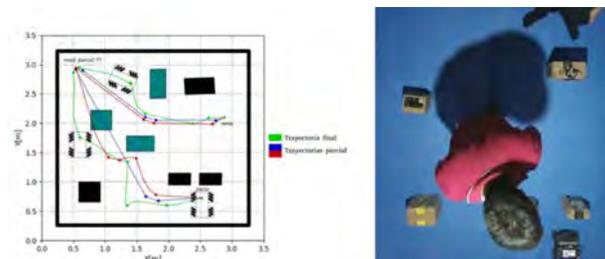


Figura 3.4 Trayectorias generadas con la presencia de obstáculos [46].

Detección de obstáculos y planos durante el desplazamiento vehicular [4].

En esta investigación se desarrolló un método para combinar la información obtenida de un sensor LiDAR y un sensor RGB-D para la identificación de vehículos en el camino. Mediante la remoción de ruido obtenido por los sensores al optimizar la nube de puntos mediante la aplicación de diferentes algoritmos como *Random Sample Consensus*, *DBSCAN* y *PointNet*. En la Figura 3.5 se muestra un esquema del sistema propuesto para la detección de obstáculos mediante el análisis y procesamiento de nubes de puntos obtenidos mediante el sensor LiDAR.

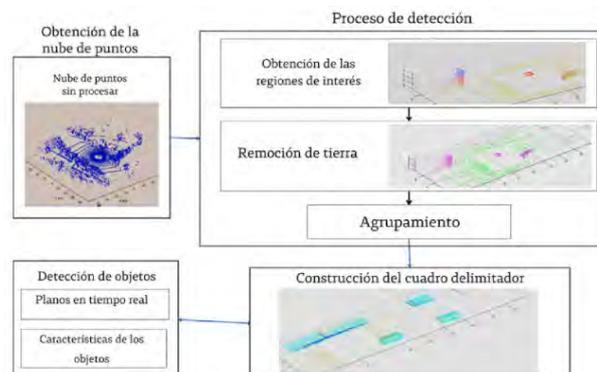


Figura 3.5 Metodología de la propuesta de solución [4].

3.2 Trabajos relacionados

Planificación de trayectorias

Dentro de este núcleo temático se recopilaron los trabajos cuyo objetivo fuese la generación de trayectorias para vehículos auto conducidos mediante cualquier método.

Trajectory optimization and state selection for urban automated driving [52]

En el artículo se presentó un método para la planificación de rutas locales en entornos urbanos, se contemplaron varios estados en los cuales el planificador de rutas se comportó de diferente manera, según fuera requerido el algoritmo se intercambió entre tres modos diferentes: modo de frenado, modo de seguimiento de vehículo guía y modo crucero. En el modo crucero se contemplaron todas las maniobras de evasión de obstáculos partiendo de una curva paramétrica para describir la ruta de referencia. En la Figura 3.6 se puede observar el diagrama para el cambio de estado.

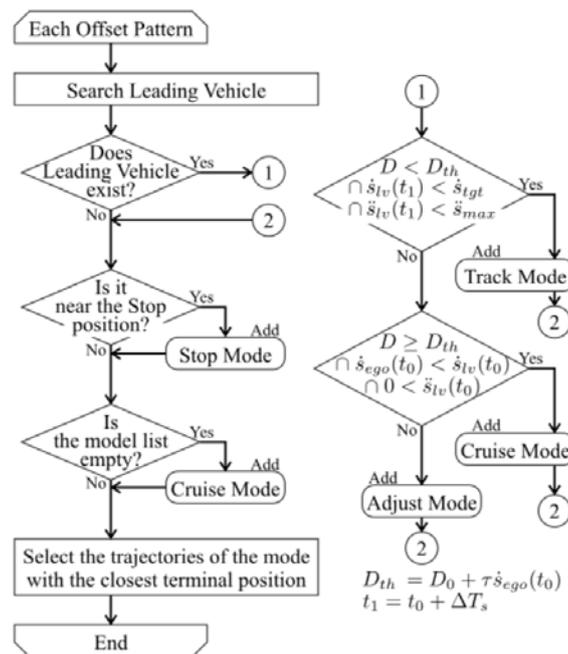


Figura 3.6 Optimización de rutas con el algoritmo HFS-A* [52].

A Path Planning and Navigation Control System Design for Driverless Electric Bus [53]

En este artículo se diseñó un sistema de control para planificar las trayectorias para la conducción automática de un autobús, a partir del algoritmo Dijkstra se creó la ruta global, el algoritmo polinomial tomó dos puntos de esta ruta como entrada y objetivo para trazar una trayectoria local. Se consideró como parámetro de mayor peso la correcta selección de los puntos de objetivo para la creación de las trayectorias, así como el máximo ángulo de giro R de las ruedas frontales, que se describió con la siguiente expresión:

$$R = d/\text{sen}(\delta_f) \quad (3.1)$$

donde δ_f es el ángulo de giro de las llantas delanteras, d es la distancia entre ejes. El algoritmo mantuvo los ángulos de las trayectorias dentro del máximo ángulo de giro del vehículo.

Intelligent Tracking Car Path Planning Based on Hough Transform and Improved PID Algorithm [29]

En este trabajo se propuso la creación de una trayectoria óptima a partir de la visión por computadora y la delimitación de la carretera para trazar una línea de referencia. Se utilizó la transformada de Hough para crear los puntos que delimitan los acotamientos de la calle y después se determinó un punto medio para la línea de carril. No presentó una validación para la trayectoria generada ni contempló limitantes del vehículo para trazar las trayectorias locales. La aportación que realizó fue realizar el trazado de trayectorias a partir del procesamiento de imágenes, como se muestra en la Figura 3.7.

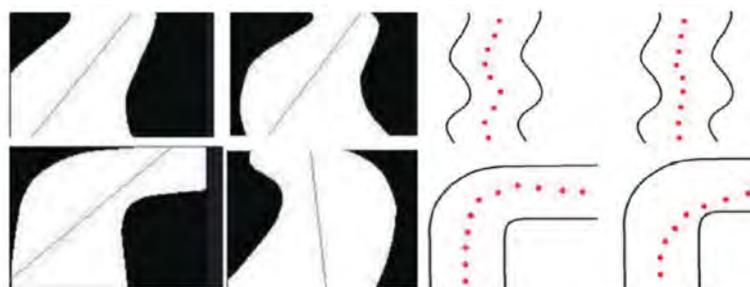


Figura 3.7 Creación de línea de referencia a partir de una imagen de la carretera [29].

A Hybrid Path Planning Algorithm Based on Simulated Annealing Particle Swarm for The Self-driving Car [51]

Este estudio contempló la creación de una trayectoria óptima para evadir obstáculos utilizando el *Simulated Annealing Particle Swarm Algorithm* que funciona mediante la determinación de un peso para realizar un cambio de estado e irse acercando a su objetivo, en la Figura 3.8 se puede observar una trayectoria generada con este algoritmo. No presentó una validación para la trayectoria generada, aunque se pudo evaluar mediante la distancia mínima entre la ruta y los obstáculos. En este artículo, al efectuar el trazado de trayectorias locales con algoritmos para rutas globales se tuvo que conocer mejor todo el entorno, además se consideró un sistema cartesiano de referencia.

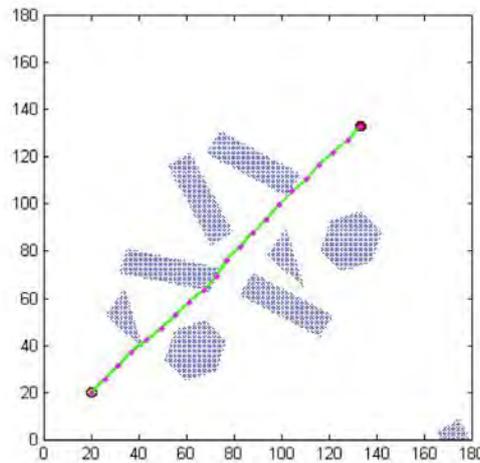


Figura 3.8 Ruta trazada por el algoritmo SAPSA [51].

Fuzzy Logic Based Self-Driving Racing Car Control System [20]

Esta investigación propuso determinar la velocidad y posición del vehículo para mantener el carril dentro de un videojuego empleando Visión por Computadora y Lógica Difusa, la primera para encontrar las líneas de carril, para después mediante la Lógica Difusa generar las señales que controlan la velocidad y la dirección del vehículo. Contemplo la medición del error al mantener el carril dado que corrige la dirección y la velocidad cuando este cruza las líneas de carril. Al usar Lógica Difusa para determinar los parámetros del vehículo, así como otras características de la curva paramétrica, se acercó a un comportamiento más natural. El diagrama del funcionamiento de este algoritmo se puede observar en la Figura 3.9.

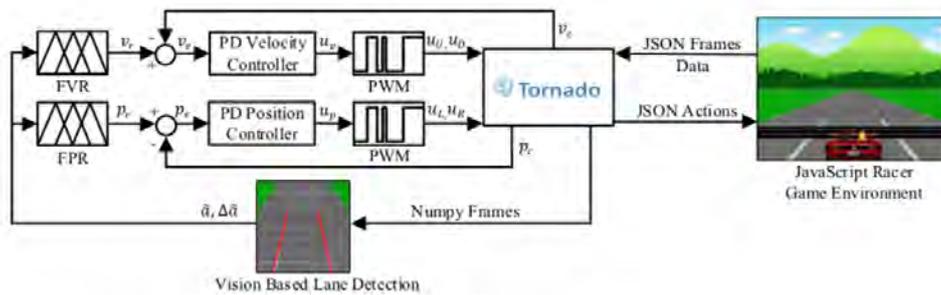


Figura 3.9 Diagrama del sistema difuso propuesto [20].

Hierarchical Evasive Path Planning Using Reinforcement Learning and Model Predictive Control [58]

En este estudio se creó una trayectoria local en tiempo real para rebasar un obstáculo en una carretera de dos carriles, contemplando una única trayectoria para las dos acciones: la evasión del obstáculo y el regreso al carril. Mediante Aprendizaje Reforzado le enseñó al algoritmo que parámetro debe tener más importancia utilizando una función de recompensa, que permitió ajustar una curva de Euler que fue la trayectoria a realizar, en la Figura 3.10 se muestra una trayectoria generada con este método. Al tener una función recompensa para incrementar el desempeño fue necesario calcular el error de la trayectoria generada para ajustar la recompensa. Esta investigación presentó la utilidad de emplear la clotoide para efectuar evasión de obstáculos y mantenimiento de carril de forma simultánea en una sola trayectoria.

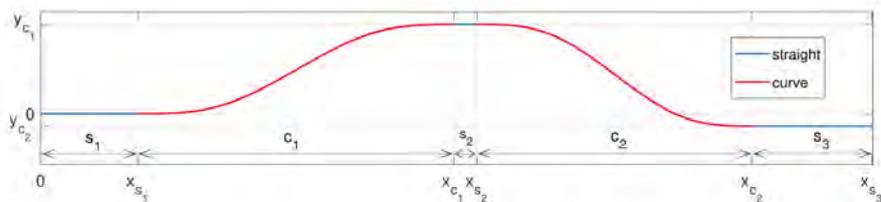


Figura 3.10 Diagrama de la composición de la trayectoria [58].

An improved DQN path planning algorithm [24]

Esta investigación propuso un sistema que implementó Aprendizaje Profundo para determinar la dirección del vehículo utilizando *Deep Q-learning Net* y una función recompensa para reforzar el aprendizaje y efectuar la toma de decisiones, así como determinar la dirección que el vehículo tomó para evadir un obstáculo. Tuvo como utilidad la implementación de Aprendizaje Profundo para la toma de decisiones con base en la percepción. en la Figura 3.11 se puede apreciar el método propuesto.

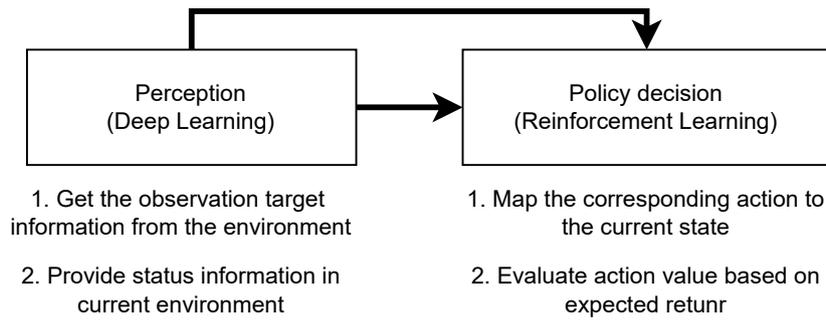


Figura 3.11 Diagrama del método propuesto [24].

Self-Adaptive Motion Prediction-Based Proactive Motion Planning for Autonomous Driving in Urban Environments [16]

Este trabajo sugirió un método para predecir la trayectoria de otros vehículos para estimar la trayectoria local. Se desarrolló un algoritmo de predicción de movimiento adaptativo y Visión por Computadora para a partir de las imágenes determinar la trayectoria de los vehículos que el sistema puede percibir. Efectuaron la validación mediante el modelo de control predictivo. La utilidad de este artículo fue efectuar la validación de las trayectorias mediante un controlador. En la Figura 3.12 se puede observar un diagrama de las etapas del método propuesto.

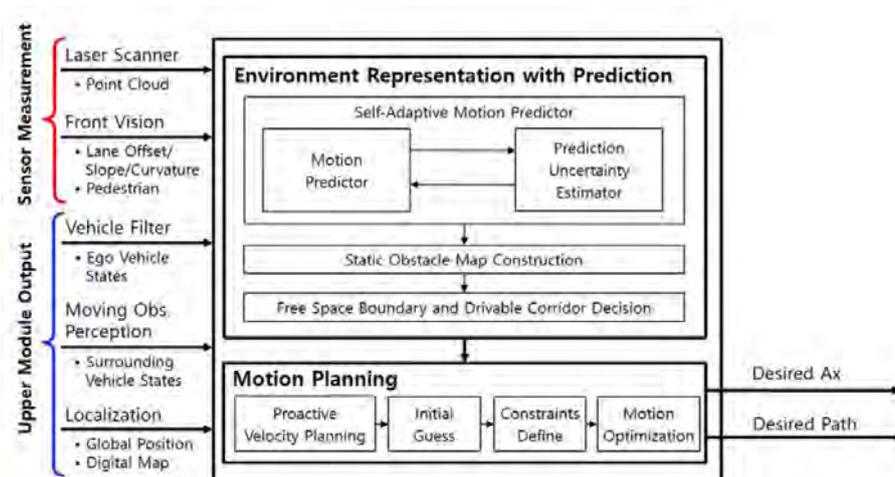


Figura 3.12 Diagrama de los diferentes bloques que integran la propuesta [16].

Game-Based Lateral and Longitudinal Coupling Control for Autonomous Vehicle Trajectory Tracking [5]

En esta investigación se propuso un método para el seguimiento de las trayectorias generadas, contemplando por separado el cálculo del costo de las acciones para controlar

la dirección y la velocidad. Se utilizó la estrategia de equilibrio de Nash para obtener una convergencia donde se satisfacían los parámetros de dirección y velocidad que se generaron con las trayectorias. Se comparó el desempeño del método propuesto con el Modelo de Control Predictivo (MPC) donde el error lateral fue menor en comparación al MPC, además tuvo mejor respuesta a los cambios de velocidad objetivo.

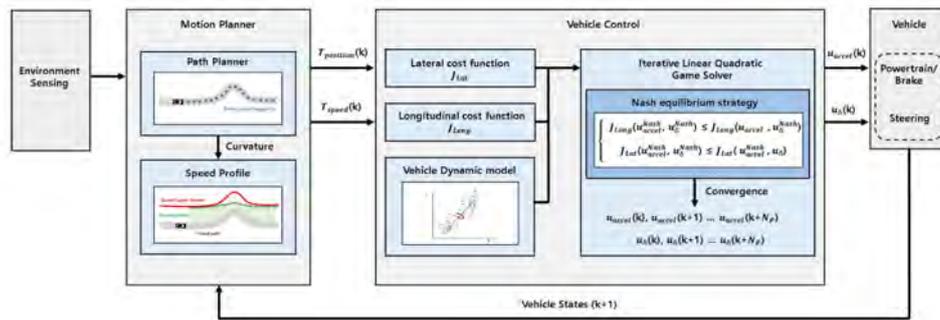


Figura 3.13 Diagrama de flujo del método propuesto [5].

Energy-Efficient Local Path Planning of a Self-Guided Vehicle by Considering the Load Position [28]

En este trabajo se propuso un método para la generación de trayectorias para un vehículo de carga. Se generó un conjunto de datos contemplando las entradas y salidas del modelo cinemático, donde se empleó un Perceptrón Multicapa para generar las predicciones a través de series de tiempo, con las cuales se obtuvieron los parámetros para las trayectorias generadas. Se contempló la carga del vehículo con relación al costo energético para generar las diferentes trayectorias. En la Figura 3.14 se muestra una representación de las trayectorias que se generaron dentro de un almacén.

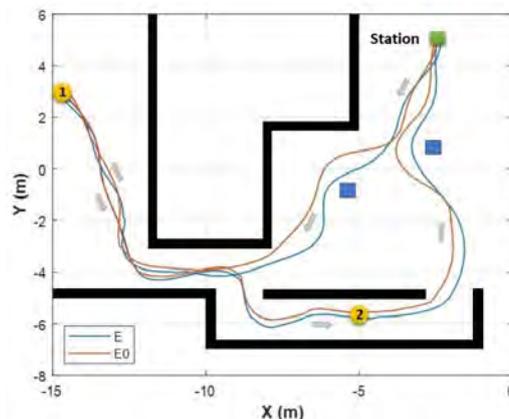


Figura 3.14 Trayectorias generadas por el método propuesto [28].

Navigation of a Differential Wheeled Robot Based on a Type-2 Fuzzy Inference Tree [30]

Dentro de esta investigación se implementó un árbol de inferencia difusa de tipo 2 para la navegación diferencial de robots móviles con ruedas, con un enfoque en la evasión de obstáculos y el alcance de objetivos. El sistema utilizó un escáner láser 2D y odometría para la evaluación en tiempo real, mostrando una eficiencia superior a la de otros métodos. En la Figura 3.15 se pueden apreciar las trayectorias generadas por los diferentes técnicas así como el método propuesto con la presencia de obstáculos estáticos.

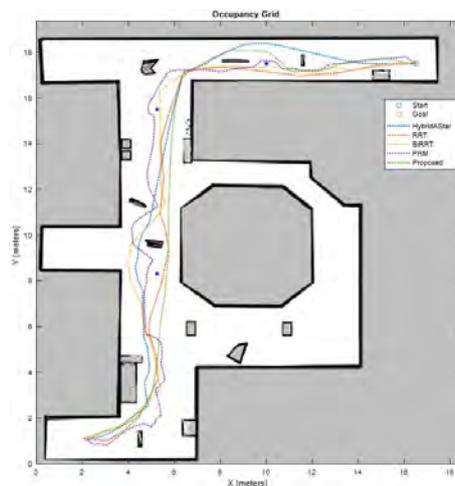


Figura 3.15 Comparativa de las diferentes trayectorias generadas [30].

Clothoid-based Trajectory Following Approach for Self-driving vehicles [14]

En este trabajo se propuso un método donde se generaron trayectorias partiendo de la unión de clotoides con segmentos de recta. Se contempló la distancia de anticipación a la curva para el ajuste de los cambios de dirección que el vehículo realizó, así como parámetros iniciales y restricciones del auto. Una vez obtenida la trayectoria se usó como referencia para el sistema de control, el cual ajustó la posición y orientación del auto, en la Figura 3.16 se puede apreciar una de las trayectorias generadas por el método propuesto.

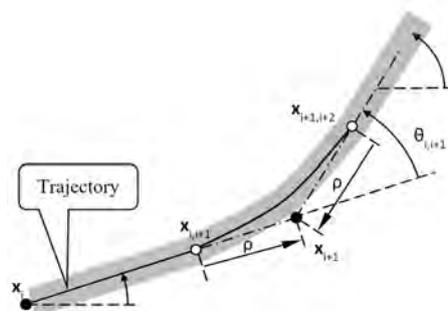


Figura 3.16 Trayectoria generada con la unión de clotoides y segmentos rectos [14].

3.3 Toma de decisiones

Dentro de esta sección se encuentran los artículos relacionados a la aplicación de métodos de toma de decisiones dentro del contexto de la selección de trayectorias y comportamiento del vehículo dentro en el camino.

Decision-making Strategy on Highway for Autonomous Vehicles using Deep Reinforcement Learning [25]

En esta investigación se desarrolló un método para la toma de decisiones respecto al comportamiento dentro de una autopista, mediante el aprendizaje de políticas para realizar las acciones de cambio de carril. Utilizaron un marco de control jerárquico donde el nivel alto controla las interacciones y el nivel bajo monitorea el vehículo. El aprendizaje profundo reforzado se empleó mediante una Red Q Profunda de Duelo (DDQN). En la Figura 3.17 se puede observar la estructura de la red DDQN para la toma de decisiones.

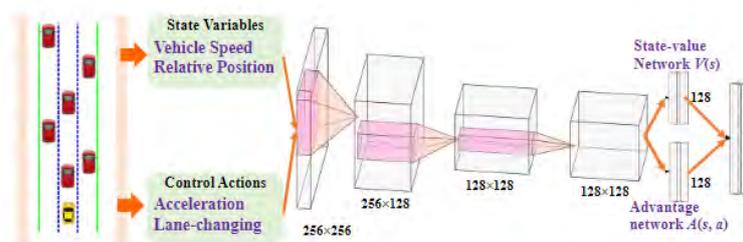


Figura 3.17 Diagrama de la red convolucional [25].

Hierarchical reinforcement learning for self-driving decision-making without reliance onlabelled driving data [6]

En esta investigación se presentaron diferentes métodos de toma de decisiones para vehículos autónomos, incluyendo el método basado en reglas y el método de aprendizaje por refuerzo jerárquico, con el cual se buscó el aprendizaje de políticas para la toma de decisiones en diferentes casos, con la finalidad que la interacción con información otros conductores ayudara a entrenar el modelo. En la Figura 3.18 se puede observar el diagrama del entrenamiento de políticas para diferentes situaciones.

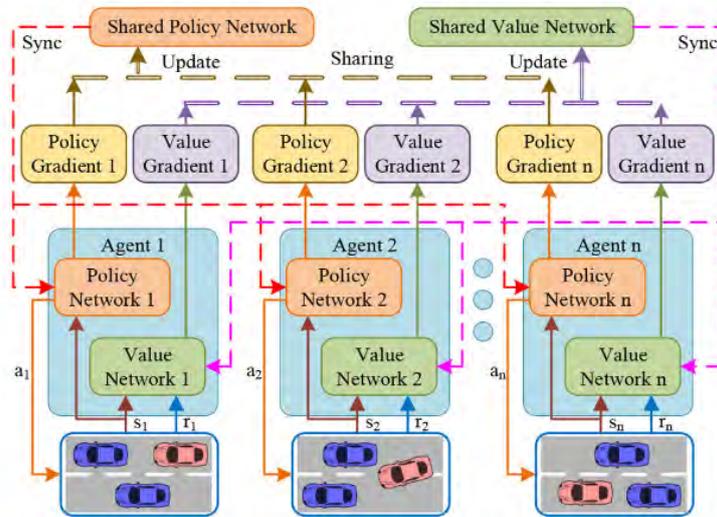


Figura 3.18 Diagrama del entrenamiento de políticas [6].

An Intelligent Lane-Changing Behavior Prediction and Decision-Making Strategy for an Autonomous Vehicle [48]

En esta propuesta se planteó un modelo de predicción para la toma de decisiones. Tomando en cuenta la información de otros conductores para la toma de decisiones mediante una máquina de estados finitos. Utilizó estados creados a través de un Modelo Oculto de Markov para realizar la toma de decisiones, con la finalidad de determinar la velocidad a la que el vehículo debe viajar en determinadas situaciones, ya sea para realizar un cambio de carril o mantener la distancia respecto al vehículo posterior. En la Figura 3.19 se puede apreciar la relación entre los bloques de predicción y toma de decisiones.

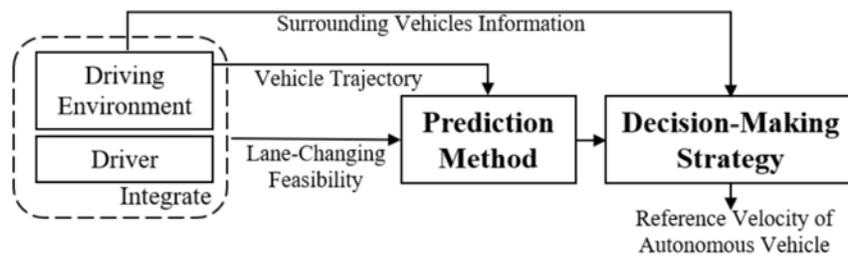


Figura 3.19 Diagrama del método propuesto [48].

Imitation learning based decision-making for autonomous vehicle control at traffic roundabouts [47]

Dentro de este trabajo se propuso un modelo de toma de decisiones basado en aprendizaje por imitación, se buscó que el modelo aprendiera mediante datos de conductores humanos,

con la finalidad de poder tomar mejor las glorietas. Se empleó Aprendizaje profundo Q con base en demostraciones reforzado con una función de recompensa para incentivar la toma de decisiones. Tomaron en cuenta datos etiquetados de expertos como guía para la toma de decisiones. Además, se conjuntaron diferentes redes para procesar la información obtenida por el módulo de percepción, como se muestra en la Figura 3.20.

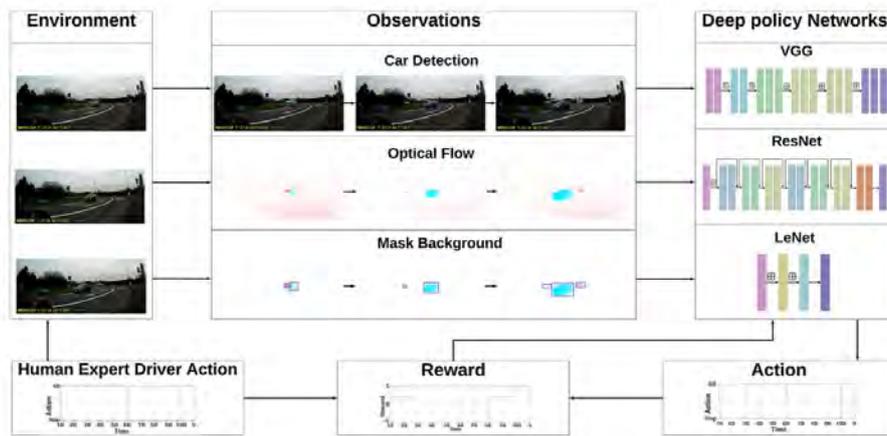


Figura 3.20 Diagrama de flujo del método propuesto [47].

Decision making framework for autonomous vehicles driving behavior in complex scenarios via hierarchical statemachine [49]

En esta investigación se propuso un marco para la toma de decisiones mediante una máquina de estados finitos jerárquica. El modelo consiste de tres capas en las que se determina el tipo de escenario en el que se encuentra el vehículo, el nivel de riesgo y la acción a realizar. Mediante estas decisiones se controló el estado en el que el vehículo debía de estar y sus respectivos cambios de estado, en la Figura 3.21 se muestra la estructura de las capas del modelo propuesto.

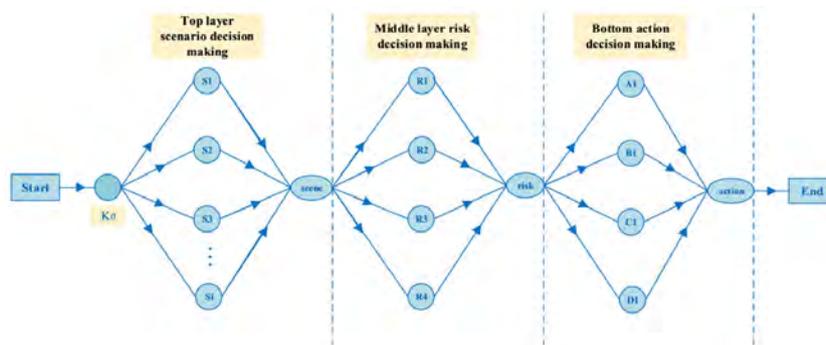


Figura 3.21 Diagrama de la interacción entre las diferentes capas del modelo propuesto [49].

Human-Like Decision Making for Autonomous Driving: A Noncooperative Game Theory Approach [10]

En este trabajo se propuso la identificación de tres modelos de conducción humanos, los cuales sería posteriormente utilizados como referencia para la toma de decisiones. Los modelos de Equilibrio de Nash y el Juego de Stackelberg se emplearon para diseñar un modelo de toma de decisiones parecido al comportamiento humano, con la finalidad de que el sistema pudiera realizar cambios de carril en vías rápidas. Este modelo se complementó con el modelo de control predictivo para generar las trayectorias y evitar las colisiones. En la Figura 3.22 se aprecia a detalle la interacción entre el modelo de los estilos de conducción y el sistema de toma decisiones del método propuesto.

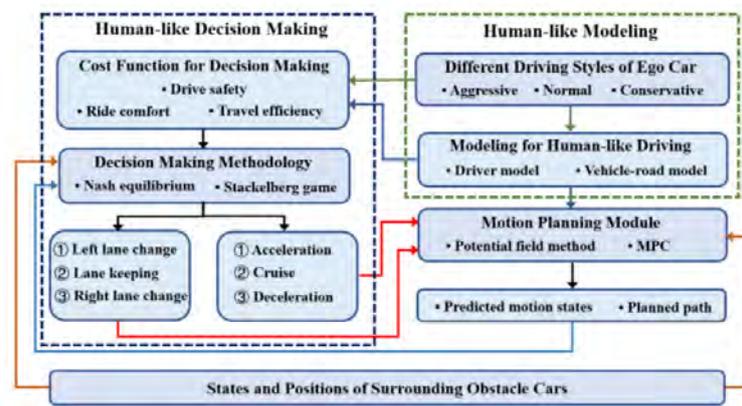


Figura 3.22 Diagrama del modelo propuesto [10].

Toward Safe and Personalized Autonomous Driving: Decision-Making and Motion Control With DPF and CDT Techniques [15]

En este trabajo se desarrolló un marco para toma de decisiones con el fin de realizar cambios de carril. Al determinar la intención del cambio de carril y la distancia entre los vehículos, el sistema tomó la decisión de caracterizarse entre tres estilos de conducción: agresivo, moderado y cuidadoso. En combinación con un módulo de planificación y control de trayectorias se cambiaba entre diferentes estilos de conducción para efectuar los cambios de carril. En la Figura 3.23 se puede observar con detalle la arquitectura propuesta por esta investigación.

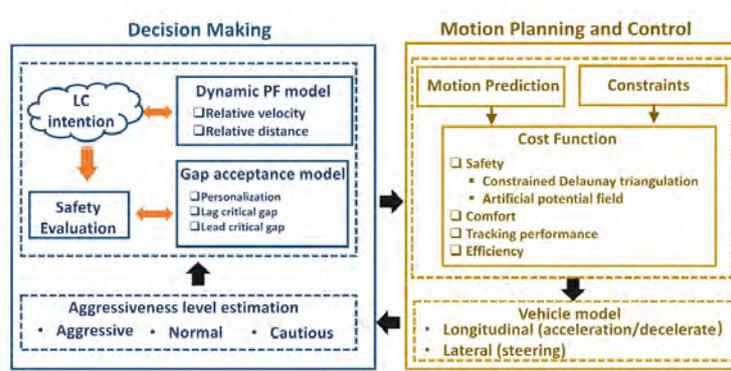


Figura 3.23 Interacción entre la toma de decisiones y la planificación y control [15].

Autonomous Driving at Intersections: A Behavior-Oriented Critical-Turning-Point Approach for Decision Making [40]

En esta investigación se desarrolló un método para la toma de decisiones sobre las vueltas a la izquierda como se puede apreciar en la Figura 3.24, debido a que se observó que existe una gran incertidumbre, se estimaron determinados puntos críticos para el giro sobre los cuales el algoritmo tenía que decidir. Mediante un proceso de decisión de Markov parcialmente observado se realizó la toma de decisiones. En la Figura 3.24 se puede observar el proceso para la toma de decisiones.

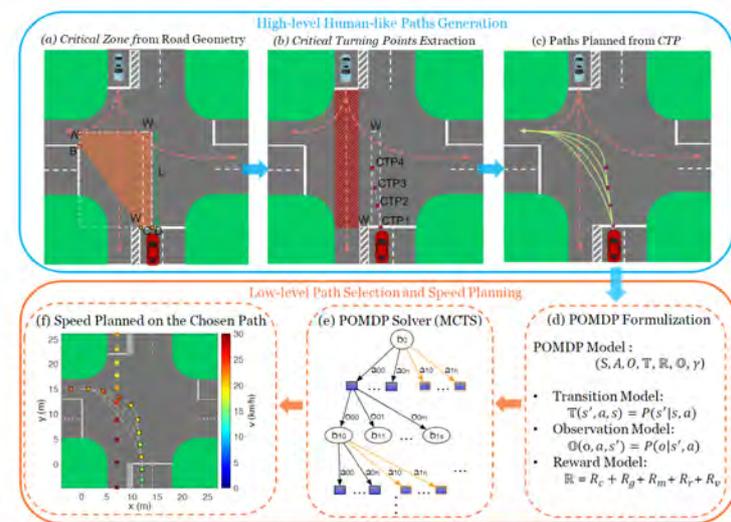


Figura 3.24 Diagrama los puntos críticos en las intersecciones [40].

Multi-Agent Decision-Making Modes in Uncertain Interactive Traffic Scenarios via Graph Convolution-Based Deep Reinforcement Learning [9]

En este trabajo se propuso que mediante una Red Neuronal de Grafos se determinó el estado de un vehículo en relación con los conductores adyacentes para poder determinar el nivel de alerta que debía prestar. Se utilizó aprendizaje reforzado mediante una función de recompensa castigo. El sistema debía decidir sobre las maniobras laterales y la aceleración longitudinal que el vehículo debía efectuar. En la Figura 3.25 se puede observar con detalle la arquitectura propuesta por esta investigación, así como el escenario en el que fue puesto a prueba el modelo propuesto.

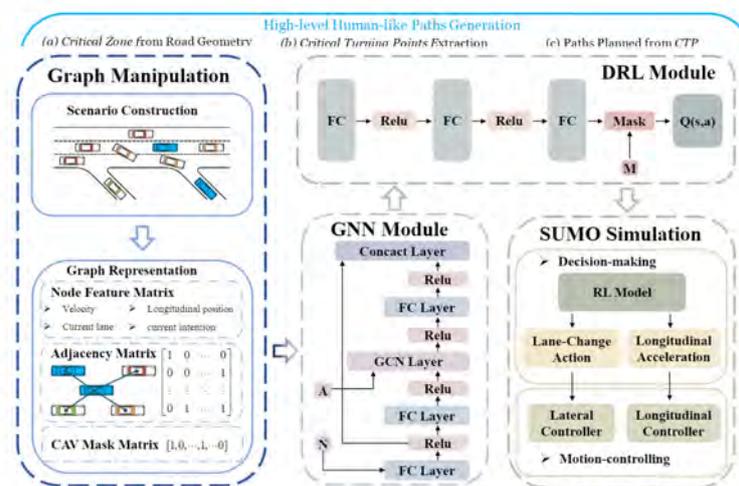


Figura 3.25 Diagrama del modelo propuesto [9].

An improved deep network-based scene classification method for self-driving cars [31]

En este artículo se propuso un método de clasificación de escenas basado en Aprendizaje Profundo. En el método propuesto, se utilizó una Red Neuronal Recurrente (RNR) para extraer las características de los objetos representativos de la escena con el fin de obtener características locales, donde se añadió un nuevo bloque de atención residual a la RNR para resaltar la semántica local relacionada con los escenarios de conducción. Además, se utilizó un módulo *Inception* mejorado para extraer características globales, donde se presentó una función mixta *Leaky ReLU* y *ELU*, para reducir la posible redundancia del kernel de convolución y mejorar la robustez. En la Figura 3.26 se muestra el diagrama de flujo del método propuesto.

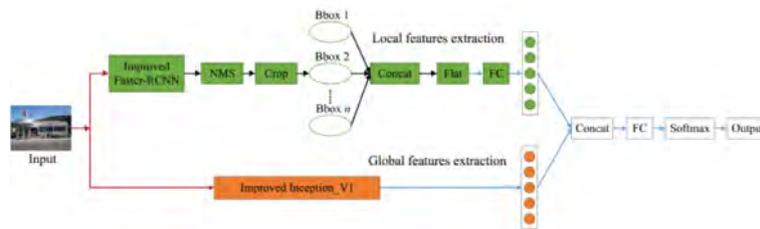


Figura 3.26 Arquitectura del modelo propuesto [31].

Autonomous highway driving using reinforcement learning with safety check system based on time-to-collision [32]

En este artículo, se utilizó el tiempo hasta la colisión (TTC) como representación de la característica y se propuso un sistema de control de seguridad basado en el TTC. La acción realizada por el controlador RL sería reemplazada por una acción más segura elegida por el sistema de control de seguridad cuando un agente detecta una posible colisión. Los resultados de la simulación muestran que el método propuesto puede mejorar la tasa de llegadas y reducir la tasa de colisiones, incluso en el caso de situaciones de tráfico denso. En la Figura 3.27 se puede apreciar la interacción propuesta entre entorno, los tiempos a la colisión y los vehículos autónomos.

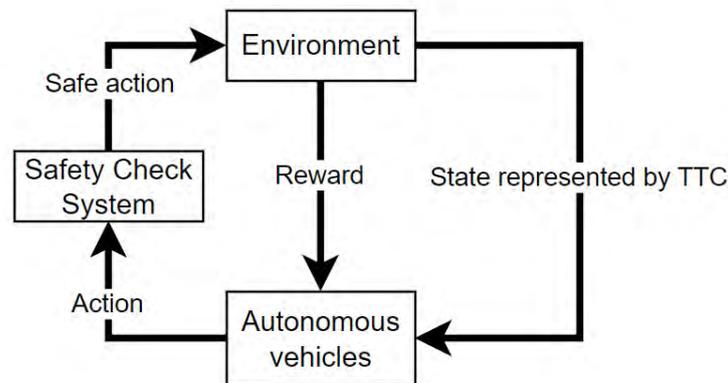


Figura 3.27 Interacción entre los elementos participantes en el sistema [32].

Tactical decision-making for autonomous driving using dueling double deep Q network with double attention [54]

Este trabajo propuso un módulo de atención espacial para calcular diferentes pesos que representen diferentes contribuciones a los resultados de la toma de decisiones. Además de un módulo de atención de canal para extraer completamente características útiles en características de estado dispersas. Estos dos módulos de atención se integraron en una Red Q Profunda Doble en Duelo, denominada D3QN-DA, como método de toma de

decisiones de alto nivel de un sistema de toma de decisiones basado en una estructura jerárquica de control. Para mejorar el rendimiento del agente, se introdujo en este sistema un verificador de seguridad de emergencia. En la Figura 3.28 se puede observar un modelo de la arquitectura propuesta.

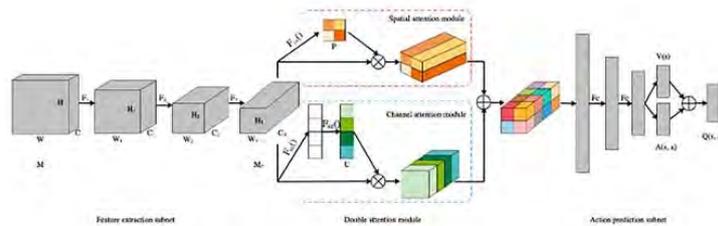


Figura 3.28 Diagrama del modelo propuesto [54].

AHP integrated TOPSIS and VIKOR methods with Pythagorean fuzzy sets to prioritize risks in self-driving vehicles [2]

Este estudio abordó la priorización de los riesgos asociados a los vehículos autoconducidos proponiendo nuevos métodos híbridos de MCDM basados en el Proceso Analítico Jerárquico (PAJ), TOPSIS y *Vlsekriterijumska Optimizacija I Kompromisno Resenje* (VIKOR) bajo entorno difuso pitagórico. El resultado del modelo propuesto se validó realizando análisis de sensibilidad. El rendimiento de la metodología propuesta con conjuntos difusos pitagóricos se comparó con el de los conjuntos difusos ordinarios, el método propuesto produjo resultados que evidencian mejor la incertidumbre de los problemas de toma de decisiones. En la Figura 3.29 se puede observar a detalle el proceso para la toma de decisiones.

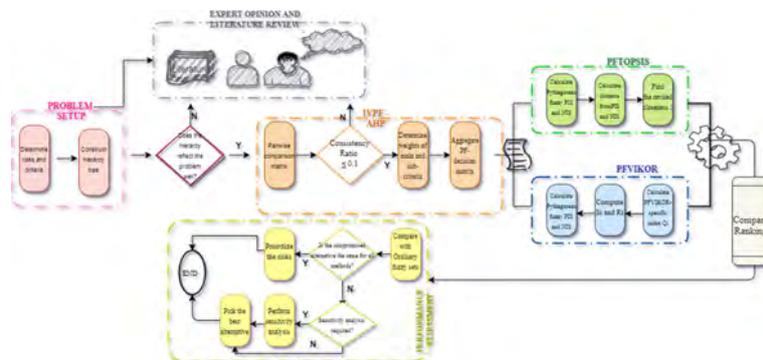


Figura 3.29 Proceso de toma de decisiones [2].

Collaborative multiagent decision making for lane-free autonomous driving [45]

Este trabajo abordó el problema de la conducción autónoma colaborativa multi agente de vehículos. Se eliminó la tarea de cambio de carril, es decir, los vehículos pudieron situarse en cualquier posición lateral arbitraria dentro de los límites de la carretera. Se formuló como un problema de colaboración multi agente representado mediante un grafo de coordinación, utilizaron funciones de utilidad locales, basadas en las interacciones entre vehículos. Obtuvieron una solución manejable y escalable estimando la acción conjunta de todos los vehículos mediante el algoritmo Max-Plus en cualquier tiempo, con funciones de utilidad locales proporcionadas por campos de potencial, diseñados para evitar colisiones. En concreto, los campos presentaron una forma elipsoidal que fue la más adecuada para entornos de autopista sin carriles. El uso de Max-Plus con campos de potencial da lugar a una política de control coordinada que exploró únicamente la información local específica de cada CAV. El movimiento sin carriles permitió aumentar la fluidez del tráfico así como aumentar la velocidad en entornos exigentes con gran afluencia de tráfico. En la Figura 3.30 se puede observar la interacción entre los vehículos.

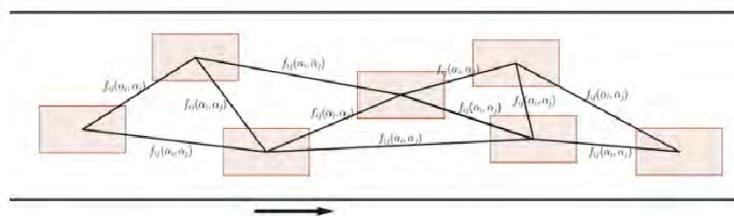


Figura 3.30 Vehículos interactuando en una carretera [45].

A decision-making model for autonomous vehicles at urban intersections based on conflict resolution [50]

En este trabajo, se propuso un enfoque para desarrollar un modelo de toma de decisiones tácticas para vehículos que fuera capaz de predecir las trayectorias de los vehículos entrantes y emplear la teoría de Resolución de Conflictos para modelar las interacciones entre vehículos. El algoritmo propuesto pretendió utilizarse para cruzar las intersecciones de forma segura. Se entrenaron modelos de Regresión de Procesos Gaussianos con los datos recogidos en las intersecciones mediante sensores y un vehículo autónomo adaptado para predecir las trayectorias de los vehículos entrantes. Se formuló un modelo de toma de decisiones para Problemas de Optimización Multiobjetivo (POM) basado en la teoría de Resolución de Conflictos en intersecciones. Después, se empleó un algoritmo genético de ordenación no dominante (NSGA-II) y un gradiente de política determinista profundo (DDPG) para seleccionar los movimientos óptimos. Se construyó una plataforma de

simulación y verificación basada en Matlab/Simulink y PreScan. Los resultados indican que DDPG es más fiable y eficaz que NSGA-II para resolver el modelo MOP, lo que proporciona una base teórica para el estudio en profundidad de la toma de decisiones en un entorno de intersección. En la Figura 3.31 se puede observar el escenario donde se probó el funcionamiento del método propuesto.



Figura 3.31 Escenario para los experimentos [50].

3.4 Discusión del estado del arte

Las investigaciones mencionadas anteriormente, presentan información relevante para el desarrollo de esta tesis. ya sea en la generación de trayectorias o en los métodos de toma de decisiones aplicados a la selección de una trayectoria. A continuación, en la Tabla 3.1 se presenta un resumen de estos artículos, considerando su objetivo, metodología, resultados obtenidos y la utilidad para esta investigación.

Tabla 3.1 Resumen del estado del arte, planificación de trayectorias.

Titulo	Objetivo	Algoritmos o técnicas utilizados	Validación utilizada	Utilidad
Trajectory optimization and state selection for urban automated driving [52].	Planificar trayectorias para un entorno urbano.	Algoritmo polinomial de quinto orden y cambio de estado para diferentes trayectorias.	Validación a través de función de pérdida con valor k para los pesos.	Emplear la referencia de Frenet y funciones de pérdida.
A Path Planning and Navigation Control System Design for Driverless Electric Bus [53].	Diseñar un método para la planificación de trayectorias de un autobús eléctrico.	Algoritmo Polinomial de quinto orden.	Solo contempla la creación de una única ruta, por lo que no hay necesidad de realizar validación.	Trazado de una trayectoria única.
<i>Intelligent Tracking Car Path Planning Based on Hough Transform and Improved PID Algorithm</i> [29].	Crear una trayectoria óptima a partir de la visión por computadora y la delimitación de la carretera .	Transformada de Hough	No menciona una validación.	Trazado de trayectorias a partir del procesamiento de imágenes.
<i>A Hybrid Path Planning Algorithm Based on Simulated Annealing Particle Swarm for The Self-driving Car</i> [51]	Creación de una trayectoria óptima para evadir obstáculos.	Simulated Annealing Particle Swarm Algorithm.	No presenta una validación para la trayectoria generada.	Trazado de trayectorias locales con algoritmos para rutas globales.
<i>Fuzzy Logic Based Self-Driving Racing Car Control System</i> [20].	Determinar la velocidad y posición del vehículo para mantener el carril.	Lógica Difusa y visión computarizada.	Medición del error al mantener el carril.	Utilizar lógica difusa para determinar los parámetros del vehículo.
<i>Hierarchical Evasive Path Planning Using Reinforcement Learning and Model Predictive Control</i> [58].	Crear una trayectoria en tiempo real para el cambio de carril en una carretera de dos carriles.	Aprendizaje reforzado y curva de Euler	Tiene una función recompensa para incrementar el desempeño.	Utilizar la clotoide como trayectoria.
<i>An improved DQN path planning algorithm</i> [24].	Crear un sistema que implemente aprendizaje profundo para determinar la dirección del vehículo	Red Q profunda y función recompensa	No mencionó validación.	Utilizar una función de recompensa para seleccionar la trayectoria.
<i>Self-Adaptive Motion Prediction-Based Proactive Motion Planning for Autonomous Driving in Urban Environments</i> [16]	Predecir la trayectoria de otros vehículos para estimar la trayectoria local.	Algoritmo de predicción de movimiento adaptativo y Visión por Computadora.	Validación mediante el modelo de control predictivo.	Validación de las trayectorias mediante un controlador.
<i>Game-Based Lateral and Longitudinal Coupling Control for Autonomous Vehicle Trajectory Tracking</i> [5]	Creación de una interfaz entre el módulo que planificación de trayectorias y el módulo de control.	Estrategia de equilibrio de Nash.	No requirió de validación.	Seguimiento de las trayectorias propuestas.
<i>Energy-Efficient Local Path Planning of a Self-Guided Vehicle by Considering the Load Position</i> [28].	Generar trayectorias eficientes para un vehículo de carga.	Perceptrón Multicapa para realizar la predicción de las trayectorias.	Medición del costo de las trayectorias.	Utilizar Redes Neuronales para generar una predicción de las trayectorias.
<i>Vehicle Trajectory Prediction based on Social Generative Adversarial Network for Self-Driving Car Applications</i> [19].	Predicción de una trayectoria con base en la estimación de las trayectorias de los vehículos circundantes	Red Neuronal Generativa Adversaria	Se compararon las trayectoria estimadas con las reales de los vehículos dentro del set de datos.	Contemplar la trayectoria de los vehículos próximos.
<i>Clothoid-based Trajectory Following Approach for Self-driving vehicles</i> [14].	Generación de trayectorias mediante la unión de clotoides	Uso del clotoide y horizonte de predicción.	Se contemplaron los parámetros iniciales y las restricciones del vehículo.	Contemplar parámetros iniciales y restricciones del vehículo.

Tabla 3.2 Resumen del estado del arte, toma de decisiones.

Titulo	Objetivo	Algoritmos o técnicas utilizados	Validación utilizada	Utilidad
<i>Decision-making Strategy on Highway for Autonomous Vehicles using Deep Reinforcement Learning</i> [25]	Toma de decisiones respecto al comportamiento dentro de una autopista.	Red Q Profunda de Duelo (DDQN).	Validación mediante la comparación de estados.	Reducir los criterios a tomar en cuenta a velocidad y posición.
<i>Hierarchical reinforcement learning for self-driving decision-making without on labelled data</i> [12].	Toma de decisiones ajustada a diferentes situaciones.	Método basado en reglas y Aprendizaje por Refuerzo Jerárquico	No mencionó validación.	Contemplar diferentes maniobras.
<i>An Intelligent Lane-Changeing Behavior Prediction and Decision-Making Strategy for an Autonomous Vehicle</i> [48]	Predicción como criterio para la toma de decisiones.	Modelo Oculito de Markov.	Validación mediante las colisiones evitadas.	Condicionar las velocidad dependiendo de la situación.
<i>Imitation learning based decision-making for autonomous vehicle control at traffic roundabouts</i> [47]	Toma de decisiones para tomar glorietas.	Aprendizaje Profundo Q.	Validación mediante datos de conductores expertos.	Utilizar datos de expertos para tomar decisiones.
<i>Decision-making Strategy on Highway for Autonomous Vehicles using Deep Reinforcement Learning</i> [25]	Toma de decisiones respecto al comportamiento dentro de una autopista.	Red Q Profunda de Duelo (DDQN).	Validación mediante la comparación de estados.	Reducir los criterios a tomar en cuenta a velocidad y posición.
<i>Human-Like Decision Making for Autonomous Driving: A Noncooperative Game Theory Approach</i> [10]	Toma de decisiones basado en tres modelos distintos de conducción.	Modelo de Equilibrio de Nash y Juego de Stackelberg.	Validación mediante la comparación de estados.	Conjuntar la generación de trayectorias con la toma de decisiones.
<i>Toward Safe and Personalized Autonomous Driving: Decision-Making and Motion Control With DPF and CDT Techniques</i> [15].	Crear un marco de toma de decisiones	DPF y técnicas CDT	No mencionó validación.	Conjuntar la generación de trayectorias con la toma de decisiones.
<i>Autonomous Driving at Intersections: A Behavior-Oriented Critical-Turning-point Approach for Decision Making</i> [12].	Toma de decisiones para giros a la izquierda en intersecciones.	Proceso de Markov Parcialmente Observado.	No mencionó validación.	Contemplar puntos críticos en las trayectorias.

Resumen del estado del arte, toma de decisiones (continuación).

Titulo	Objetivo	Algoritmos o técnicas utilizados	Validación utilizada	Utilidad
<i>Multi-Agent Decision-Making in Uncertain Interactive Traffic Scenarios via Graph Convolution-Based Deep Reinforcement Learning</i> [9]	Predicción Del nivel de alerta para realizar cambios de carril y toma de intersecciones.	Red Neuronal de Grafos.	Validación mediante función de recompensa.	Considerar las interacciones con otros vehículos para realizar el cambio de carril.
<i>An improved deep network-based scene classification method for self-driving cars</i> [31].	Clasificación de escenas.	Red Neuronal Recurrente y modulo <i>Inception</i> mejorado.	No mencionó validación.	Contemplar métodos para la extracción de características de otros vehículos.
<i>Autonomous highway driving using reinforcement learning with safety check system based on time to collision</i> [32]	Selección de la acción a efectuar basada en la seguridad.	Controlador RL y verificación de las colisiones.	Validación mediante las colisiones evitadas.	Considerar condiciones con diferentes densidades de trafico.
<i>Tactical decision-making for autonomous driving using dueling double deep Q network with double attention</i> [54]	Calcular los pesos para la toma de decisiones.	Red Q Profunda Doble en Duelo, denominada D3QN-DA.	Validación mediante un verificador de seguridad.	Utilizar aprendizaje profundo para calcular los pesos y el impacto.
<i>AHP integrated TOPSIS and VIKOR methods with Pythagorean fuzzy sets to prioritize risks in self-driving vehicles</i> [2].	Clasificación de escenas.	Red Neuronal Recurrente y modulo <i>Inception</i> mejorado.	No mencionó validación.	Contemplar métodos para la extracción de características de otros vehículos.
<i>Collaborative multiagent decision making for lane-free autonomous driving</i> [45]	Coordinar un vehículo en una carretera como una tarea colaborativa.	Algoritmo Max-Plus.	Validación mediante las colisiones evitadas.	Considerar el problema de la autoconducción en una carretera como un problema multi agente.
<i>A decision-making model for autonomous vehicles at urban intersections based on conflict resolution</i> [50]	Realizar una toma de decisiones táctica.	Algoritmo genético de ordenación no dominante (NSGA-II) y un gradiente de política determinista profundo (DDPG).	Validación mediante las interacciones realizadas.	Considerar las interacciones entre vehículos.

Capítulo 4

Metodología de Solución

4.1 Propuesta de solución

Para cumplir con el objetivo general de esta investigación, se planteo generar un conjunto de trayectorias, mediante los algoritmos polinomiales de quinto orden, sobre una curva paramétrica que describe el camino sobre la cual se construyó el espacio de Frenet. De las trayectorias obtenidas posteriormente se realizó la selección de la más adecuada, de acuerdo a la situación en la que se encontrara el vehículo, mediante un método de toma de decisiones con múltiples criterios, la conjunción de todos estos elementos se puede observar con detalla en el diagrama de la Figura 4.1.

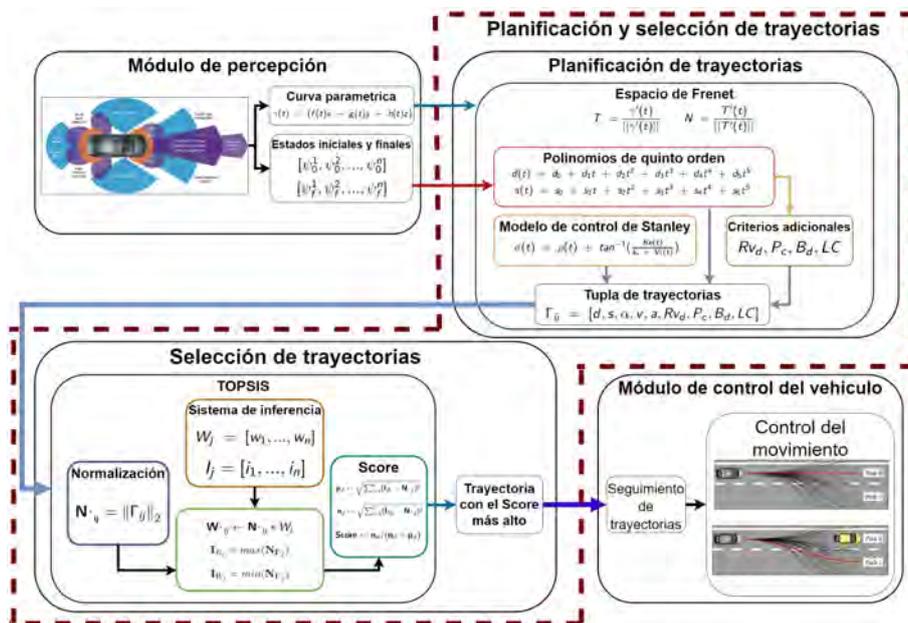


Figura 4.1 Diagrama de la propuesta de solución.

A continuación se describen cada uno de los módulos que intervienen en el funcionamiento de la propuesta de solución, así como su función en la metodología.

4.1.1 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. En la Figura 4.2 se muestra la obtención de la información necesaria mediante los diferentes sensores del vehículo.

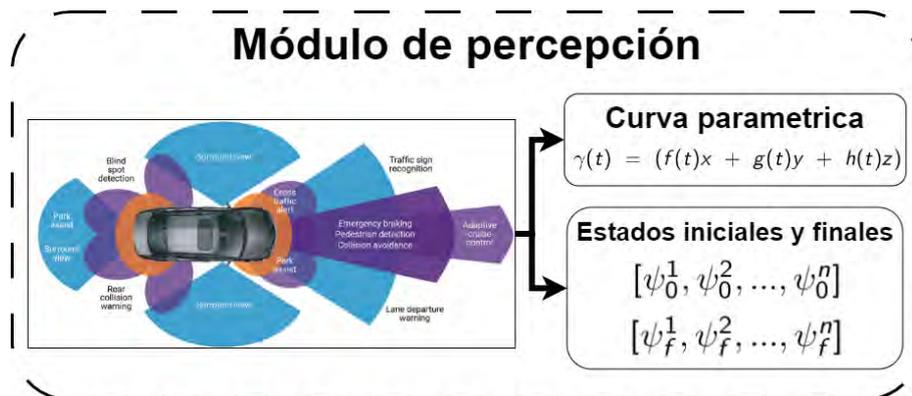


Figura 4.2 Diagrama del módulo de percepción.

4.1.2 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 \mathbb{T} y normal principal \mathbb{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 variables para todos los puntos que conforman la trayectoria. La Figura 4.3 muestra el proceso para generar este conjunto.

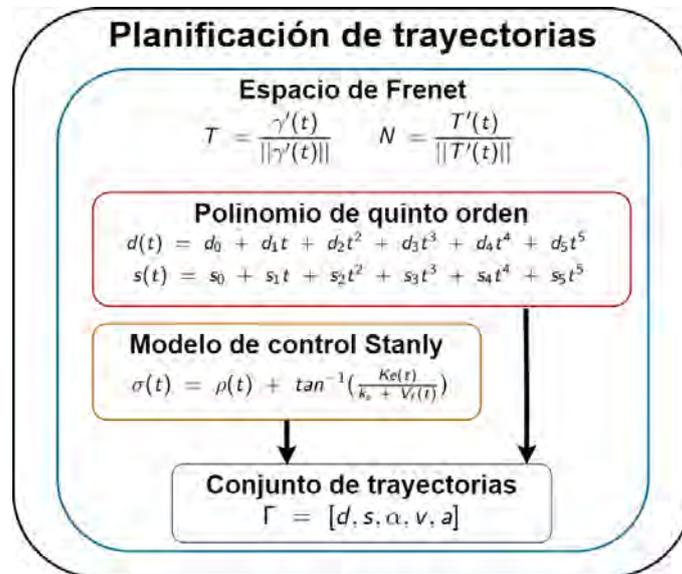


Figura 4.3 Diagrama del módulo de generación de trayectorias.

4.1.3 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 \mathbf{I}_{B_j} y \mathbf{I}_{W_j} . Finalmente se obtuvo un puntaje o *Score* mediante el cálculo de la distancia euclidiana entre las trayectorias y los valores ideales. La Figura 4.4 muestra en detalle el proceso llevado a cabo dentro del módulo de selección de trayectorias

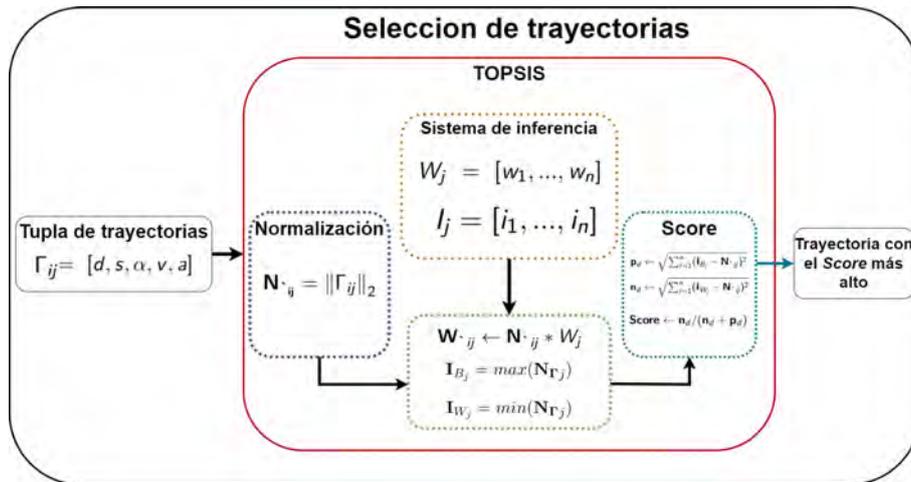


Figura 4.4 Diagrama del módulo de selección de trayectorias.

4.1.4 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 este caso fue la trayectoria seleccionada en el módulo anterior. La Figura 4.5 muestra el ajuste en maniobras longitudinales mediante el control de la aceleración del vehículo y laterales a través de la corrección del ángulo de la dirección, realizadas por el módulo de control.

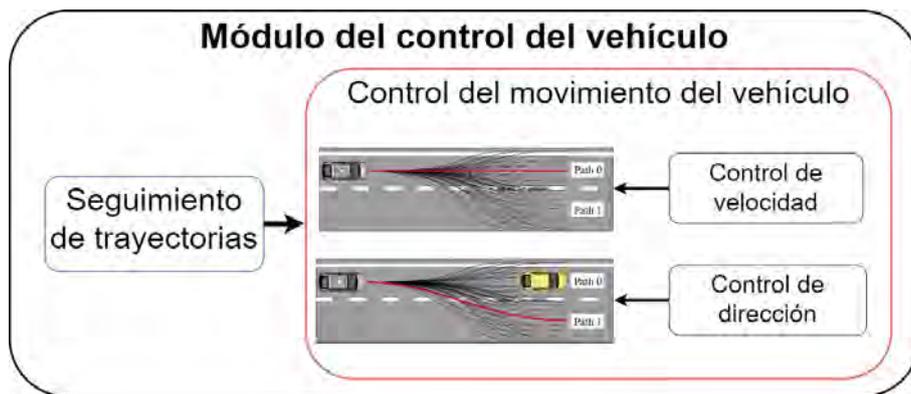


Figura 4.5 Diagrama del módulo de control del vehículo.

Capítulo 5

Experimentación y Resultados

5.1 Diseño Experimental

En esta sección se detallan los experimentos diseñados para la evaluación del método propuesto de solución, así como las métricas empleadas y comparaciones con diferentes enfoques que se encuentran en la literatura, además de los resultados correspondientes para cada experimento.

5.2 Entorno de desarrollo

Para llevar a cabo los experimentos, y debido a que todo se realizó a nivel de simulación fue necesario contar con un equipo que tenga las prestaciones necesarias para procesar la carga de trabajo, así como el software especializado con sus respectivas librerías. Por lo tanto, ya que en los experimentos realizados el uso medio de los recursos fue elevado, se utilizó un equipo de cómputo con las siguientes características:

Arquitectura de hardware

- Procesador AMD Ryzen 5 3600 @ 3.6 GHz
- 16 GB de memoria RAM
- Disco de estado sólido de 1 TB
- GPU RX 580 con 8 GB de VRAM

Arquitectura de software

- Sistema operativo Windows 11 Pro
- Sistema operativo Ubuntu 22.04 LTS
- MATLAB R2021a
- Python 3.11

5.3 Escenario de conducción

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 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 5.1 se puede apreciar el escenario en el cual se llevaron a cabo los experimentos.

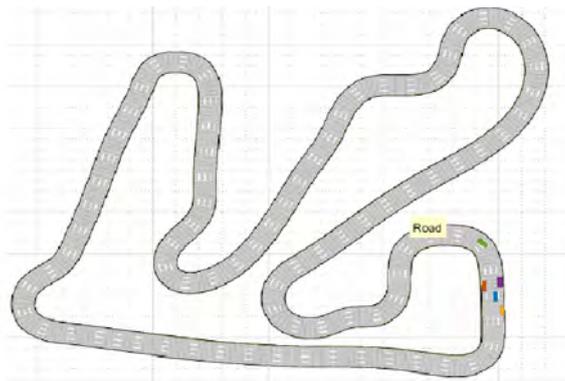


Figura 5.1 Escenario diseñado para los experimentos.

además de esto las características del vehículo dentro de la simulación fueron:

- Largo del vehículo: 4.5 m
- Ancho del vehículo: 1.9 m

5.4 Métricas

Con la finalidad de cuantificar el desempeño del método propuesto, se tomaron como referencia, las siguientes métricas propuestas en [9] las cuales miden ciertos parámetros de la conducción ligados a la expertise del conductor, y de esta forma se evaluó el comportamiento del algoritmo de toma de decisiones. Las métricas empleadas son las siguientes: eficiencia, seguridad y confort.

Eficiencia

La eficiencia se puede denotar como 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 siguientes funciones:

$$\bar{v}_{AVs} = \frac{\sum_{i=1}^n \sum_{j=1}^m v_{AV - ij}}{N} \quad (5.1)$$

$$\bar{v}_S = \frac{\sum_{i=1}^n \sum_{j=1}^m v_{ij}}{N_{all}} \quad (5.2)$$

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.

Seguridad

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:

$$\mathbf{P}_{colision} = \frac{N_{colision}}{N_{NCV}} \quad (5.3)$$

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

Confort

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 $(-\infty, -4.5 \text{ m} \cdot \text{s}^{-2})$.

Índice de Frecuencia y Calidad de Cambio de Carril (LCFQI)

Esta métrica se compone por dos partes principales: Frecuencia de Cambio de Carril (LCF) 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) 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.

$$LCFQI = (\alpha \cdot LCF) + (\beta \cdot LCQ). \quad (5.4)$$

donde α y β son factores de ponderación que determinan la importancia relativa de la frecuencia y la calidad.

$$LCQ = w_s \cdot S + w_{sa} \cdot S_a + w_{ap} \cdot A_p. \quad (5.5)$$

donde S denota el componente de suavidad, S_a denota el componente de seguridad, A_p representa el componente de adecuación, y w_s , w_{sa} y w_{ap} son factores de ponderación para cada subcomponente, respectivamente.

5.5 Experimentos

Con el esquema de solución definido, el cual se muestra en el diagrama 4.1, se condujeron una serie de experimentaciones con la finalidad de probar el desempeño del mismo variando diferentes criterios y bajo diferentes condiciones. Los objetivos de la serie de experimentaciones se detallan en los siguientes puntos:

- Realizar un ajuste fino de los vectores de peso e impacto.
- Probar el rendimiento de estos vectores con la presencia de obstáculos estáticos y dinámicos.
- Probar el rendimiento y tiempo de respuesta variando la velocidad en las simulaciones.
- Realizar el ajuste fino de los vectores de peso e impacto con la inclusión de nuevos criterios.
- Probar la transferencia de experiencia al modelo mediante datos recolectados de conductores.
- Comparar el desempeño de diferentes estilos de conducción.
- Probar el rendimiento y tiempo de respuesta variando la velocidad en las simulaciones.
- Comparar el esquema propuesto con métodos convencionales.
- Comparar el esquema propuesto con métodos del estado del arte.

5.5.1 Experimentación con el ajuste fino de los vectores de peso e impacto

El algoritmo TOPSIS utiliza parámetros como los vectores de impacto y peso para seleccionar trayectorias. Se realizó una experimentación inicial generando estos vectores de forma aleatoria. Para el vector de peso, se asignaron números enteros en el rango de $[1, 5]$ para cada criterio, mientras que para el vector de impacto, cada criterio solo puede tener dos valores (+, -), lo que dio ocho combinaciones posibles para los criterios de ángulo de giro α , velocidad v y aceleración a .

El experimento se llevó a cabo en el escenario de la Figura 5.1, donde el vehículo viajó sin obstáculos y con un límite de velocidad de 40 km/h . Se probaron 400 de las 1000 combinaciones posibles de vectores W e I en el algoritmo, que luego se evaluaron en el escenario de conducción para medir su desempeño según varias métricas. Los resultados de los 20 mejores pares de vectores en las métricas se muestran en la Tabla 5.1.

Tabla 5.1 Resultados para el ajuste fino de los vectores W e I .

Vector W, I	Efficiency	Comfort	LCFQI
[2,5,5],[-,+]	40	0.6	5.4
[3,5,5],[-,+]	40	0.52	4
[2,5,4],[-,+]	40	0.59	4.8
[3,5,4],[-,+]	40	0.5	4.2
[2,5,3],[-,+]	40	0.56	4.6
[3,5,3],[-,+]	40	0.43	4.2
[2,4,5],[-,+]	39	0.54	4
[3,4,5],[-,+]	39	0.49	3.6
[2,4,4],[-,+]	39	0.52	3.8
[3,4,4],[-,+]	39	0.46	3.2
[2,4,3],[-,+]	39	0.48	3.6
[3,4,3],[-,+]	39	0.41	2.8
[2,4,2],[-,+]	39	0.45	2.8
[3,4,2],[-,+]	39	0.38	1.8
[3,3,5],[-,+]	39	0.4	2.4
[2,3,5],[-,+]	38	0.36	3.6
[3,3,4],[-,+]	38	0.39	3
[2,3,4],[-,+]	38	0.34	2.4
[3,3,2],[-,+]	38	0.37	2.8
[2,3,2],[-,+]	37	0.32	2.2
[2,2,4],[-,+]	37	0.33	2.4

El peso asignado a cada criterio determina su importancia para la toma de decisiones por lo tanto se buscó encontrar un balance para obtener un manejo estable, en este sentido se consideraron en primera instancia las tuplas que alcanzaron los resultados más altos en la métrica *Efficiency* seguidos de las pares con un mejor *Comfort* y por último las duplas con con mejores resultados en la métrica *LCFQI*. Es necesario mencionar que debido a que no existieron obstáculos de ningún tipo en esta experimentación, no se contempló la métrica *Safety*.

De acuerdo, a los resultados presentados en la Tabla 5.1, se puede observar que los vectores que obtuvieron un mejor desempeño mantienen una mayor importancia en la reducción de los ángulos de giro. Lo cual reduce los cambios de carril, seguido del aumento de la velocidad, con lo que se mejoró el tiempo en el cual se recorre el circuito, lo que aumenta la eficiencia del modelo y, por último, consideraron una reducción en la aceleración, con lo que se incrementó el confort dentro del vehículo.

Los resultados de todas las combinaciones probadas en las métricas, se pueden observar en el gráfico de la Figura 5.2, en el cual se muestran los valores normalizados para los resultados obtenidos.

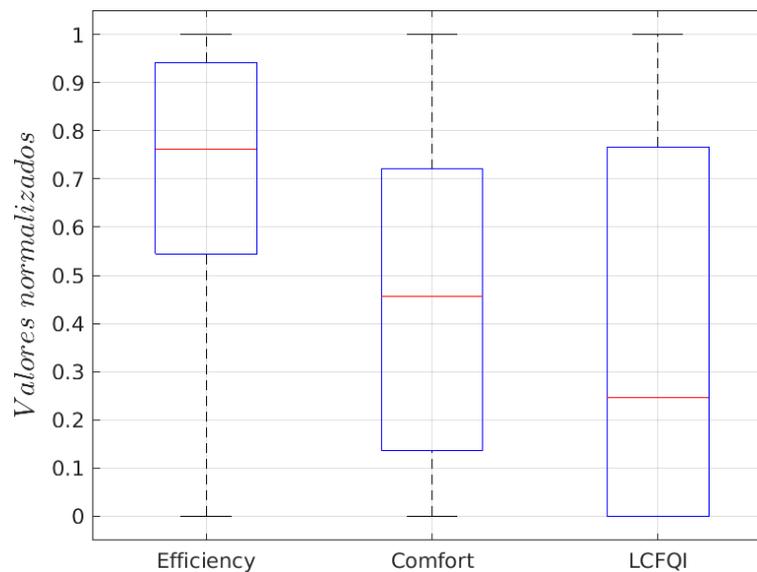


Figura 5.2 Resultados en las métricas para las combinaciones contempladas.

En este gráfico, el valor de la línea roja es el valor de la mediana de los resultados, la caja azul representa la distribución de los datos, y las líneas negras los valores extremos. Podemos observar que el confort del vehículo es relativamente bueno debido a que no hay obstáculos que requieran que se lleven a cabo maniobras de cambio de carril, lo cual se puede apreciar con la tendencia a la baja de la métrica *LCFQI*; además de esto la eficiencia se mantiene elevada debido a que no existen obstáculos que limiten el movimiento, aunque

existen casos de valores extremos donde el vehículo va a muy baja velocidad de acuerdo con el ajuste de la preferencia para reducir este criterio.

5.5.2 Experimentación en un escenario con la presencia de obstáculos estáticos

El objetivo de esta experimentación es observar el comportamiento de los vectores de la Tabla 5.1 obtenidos en el experimento 5.5.1, en el escenario de la Figura 5.1 con presencia de obstáculos estáticos colocados a lo largo del camino en cualquiera de los cuatro carriles, estos obstáculos son barreras de concreto con dimensiones de 1.5 m por 0.4 m. El desempeño de las duplas fue cuantificado utilizando las métricas mencionadas en la sección 5.4, los resultados se pueden observar en la Tabla 5.2.

Tabla 5.2 Resultados obtenidos con la presencia de obstáculos estáticos

Vector W, I	Safety	Efficiency	Comfort	LCFQI
[2,5,5],[-,+,+]	6	37	0.87	6.2
[3,5,5],[-,+,+]	6	37	0.79	4.8
[2,5,4],[-,+,+]	5.8	37	0.86	5.6
[3,5,4],[-,+,+]	5.6	37	0.77	5.2
[2,5,3],[-,+,+]	5.4	37	0.83	5.4
[3,5,3],[-,+,+]	5.2	37	0.7	4
[2,4,5],[-,+,+]	5	36	0.81	4.8
[3,4,5],[-,+,+]	4.8	36	0.76	4.4
[2,4,4],[-,+,+]	4.6	36	0.79	4.6
[3,4,4],[-,+,+]	4.4	36	0.73	4
[2,4,3],[-,+,+]	4.2	36	0.75	4.4
[3,4,3],[-,+,+]	4	36	0.68	3.6
[2,4,2],[-,+,+]	3.8	35	0.72	3.6
[3,4,2],[-,+,+]	3.6	35	0.65	2.6
[3,3,5],[-,+,+]	3.4	35	0.67	2.6
[2,3,5],[-,+,+]	3.2	34	0.63	4.4
[3,3,4],[-,+,+]	3	34	0.66	5.8
[2,3,4],[-,+,+]	2.8	34	0.61	4.2
[3,3,2],[-,+,+]	2.6	34	0.64	5.8
[2,2,4],[-,+,+]	2.4	33	0.59	3.4

Se puede observar claramente que al incluir los obstáculos se reduce ligeramente el rendimiento de los pares de vectores, debido a que para evitar los obstáculos es necesario realizar cambios de carril, en el caso de los vectores con un mayor peso para la reducción del ángulo de giro α se observa un incremento considerable en las colisiones con los obstáculos estáticos. En su contraparte las duplas que tienen un mayor resultado en la métrica *LCFQI* tienen el mayor número de colisiones.

Los resultados de todas las combinaciones probadas en las métricas, se pueden observar en el gráfico de la Figura 5.3, en el cual se muestran los valores normalizados para los resultados obtenidos.

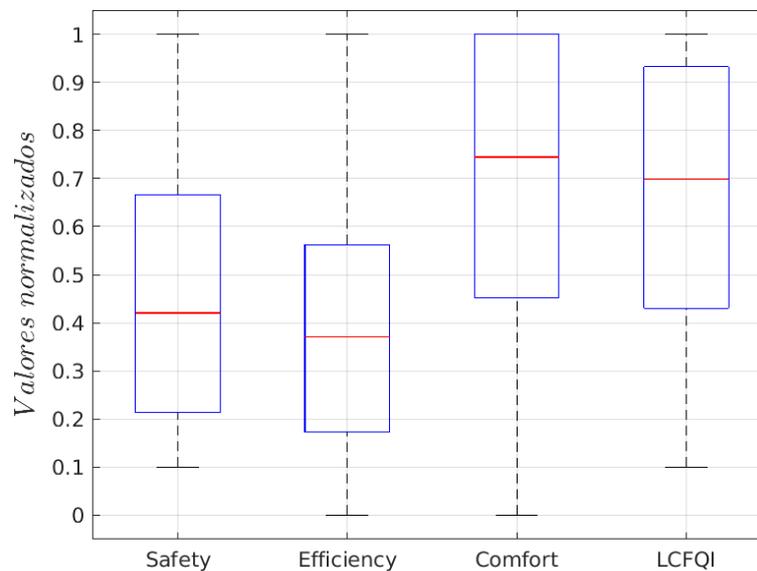


Figura 5.3 Resultados en las métricas con obstáculos estáticos.

En este gráfico podemos observar que la eficiencia disminuye debido a que existen obstáculos que limitan el movimiento, aunque existen casos de valores extremos donde el vehículo va a muy baja velocidad por el ajuste de los vectores W e I . Además hay pocas colisiones debido a que los obstáculos son estáticos, y no cambian de posición a lo largo del camino. El confort del vehículo disminuye en relación al aumento de maniobras de cambio de carril, lo cual se puede apreciar con la métrica *LCFQI* la cual tiene un valor medio más elevado.

5.5.3 Experimentación en un escenario con la presencia de obstáculos dinámicos

El objetivo de este experimento fue observar el comportamiento de los vectores de la Tabla 5.1 obtenidos en el experimento 5.5.1, con presencia de obstáculos dinámicos (otros vehículos en movimiento) desplazándose a lo largo del camino en cualquiera de los cuatro carriles, estos obstáculos son autos con las mismas dimensiones al vehículo controlado. El desempeño de las duplas fue cuantificado utilizando las métricas mencionadas en a sección 5.4, los resultados se pueden observar en la Tabla 5.3.

Tabla 5.3 Resultados obtenidos con la presencia de obstáculos dinámicos

Vector W, I	Safety	Efficiency	Comfort	LCFQI
[2,5,5],[-,+,+]	6.8	29	0.99	7.2
[3,5,5],[-,+,+]	6.8	29	0.91	5.8
[2,5,4],[-,+,+]	6.6	29	0.98	6.6
[3,5,4],[-,+,+]	6.4	29	0.89	2.2
[2,5,3],[-,+,+]	6.2	29	0.95	6.4
[3,5,3],[-,+,+]	6	29	0.82	6
[2,4,5],[-,+,+]	5.8	28	0.93	5.8
[3,4,5],[-,+,+]	5.6	28	0.88	5.4
[2,4,4],[-,+,+]	5.4	28	0.91	5.6
[3,4,4],[-,+,+]	5.2	28	0.85	5
[2,4,3],[-,+,+]	5	28	0.87	5.4
[3,4,3],[-,+,+]	4.8	28	0.8	4.6
[2,4,2],[-,+,+]	4.6	27	0.84	4.6
[3,4,2],[-,+,+]	4.4	27	0.77	3.6
[3,3,5],[-,+,+]	4.2	27	0.79	4.2
[2,3,5],[-,+,+]	4	26	0.75	5.4
[3,3,5],[-,+,+]	3.8	26	0.78	4.8
[2,3,4],[-,+,+]	3.6	26	0.73	5.2
[3,3,2],[-,+,+]	3.4	26	0.76	4.8
[2,2,4],[-,+,+]	3.2	25	0.71	5.4

En los resultados se observa una reducción del rendimiento del modelo, en específico en el número de colisiones, el cual aumentó en todos los pares de vectores, además se redujo la eficiencia del modelo debido a que las trayectorias erráticas de los otros vehículos impedían la conducción fluida del vehículo ego. Esto evidencia que en el caso de tener presencia de obstáculos los criterios que se tomaron en cuenta no son suficientes para seleccionar una trayectoria adecuada.

Los resultados en las métricas de todas las combinaciones con la presencia de obstáculos dinámicos, se pueden observar en el gráfico de la Figura 5.4, en el cual se muestran los valores normalizados para los resultados obtenidos.

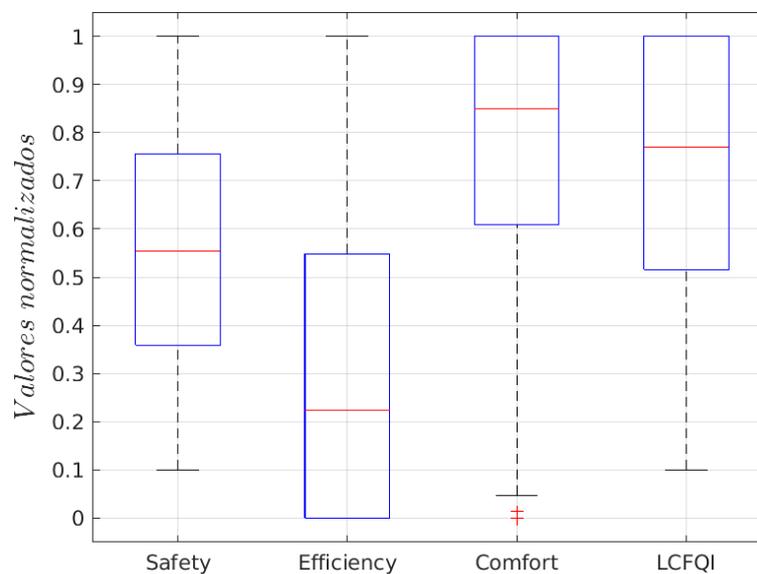


Figura 5.4 Resultados en las métricas con obstáculos dinámicos.

En este gráfico, el valor de la línea roja es el valor de la mediana de los resultados, la caja azul representa la distribución de los datos, y las líneas negras los valores extremos. Podemos observar que el confort del vehículo es relativamente bueno debido a que no hay obstáculos que requieran que se lleven a cabo maniobras de cambio de carril, lo cual se puede apreciar con la tendencia a la baja de la métrica LCFQI; además de esto la eficiencia se mantiene elevada debido a que no existen obstáculos que limiten el movimiento, aunque existen casos de valores extremos donde el vehículo va a muy baja velocidad de acuerdo con el ajuste de la preferencia para reducir este criterio.

5.5.4 Experimentación con la inclusión de criterios adicionales

Como resultado de la primer etapa de experimentos se observó que era necesario incluir criterios adicionales para lograr que el vehículo realizara una conducción con mayor estabilidad. Como se muestra en el experimento anterior, sólo se tomaron en cuenta tres criterios en el proceso de toma de decisiones: velocidad promedio, aceleración máxima y ángulo de dirección. A pesar de los buenos resultados obtenidos, es necesario agregar criterios adicionales para obtener un proceso de toma de decisiones más informado. Así que se decidió incluir cuatro parámetros adicionales:

- Rv_d : La distancia desde el vehículo ego hasta el vehículo trasero, que se puede obtener de la siguiente expresión, donde se aplica la distancia euclidiana:

$$Rv_d = \sqrt{(d_{v1} - s_{v1})^2 + (s_{v2} - s_{v2})^2} \quad (5.6)$$

donde d_{vn} corresponde a la posición del vehículo n en el eje d y s_{vn} es la posición del vehículo n en el eje lateral s .

- P_c : La posición relativa del vehículo respecto al centro del carril, que se puede calcular mediante la diferencia entre las coordenadas del centro del eje delantero y el centro del carril. Este valor se obtiene de la siguiente expresión:

$$P_c = \sqrt{(s_v - s_{CL})^2} \quad (5.7)$$

donde s_v corresponde a la posición del vehículo n en el eje s y s_{CL} es el centro del carril en el eje lateral s .

- B_d : El espacio de frenado de emergencia en relación con la velocidad del vehículo, que se puede obtener de la siguiente ecuación:

$$B_d = \frac{v^2}{2 \cdot a} \quad (5.8)$$

donde v es la velocidad máxima del vehículo, el espacio calculado puede ajustar la distancia de frenado a las velocidades más bajas en la trayectoria, y a es la desaceleración. Para este trabajo, se asume un valor constante de desaceleración de $-5m/s^2$, lo que significa que el sistema de frenado del automóvil puede reducir la velocidad del automóvil a una tasa de 5 metros por segundo al cuadrado.

- LC : El número de cambios de carril realizados por la trayectoria generada, este valor se obtuvo a partir de las coordenadas del vehículo $d(t)$ y $d(t - 1)$ y el ancho del carril w_l .

$$LC = \sum_{i=1}^n \left[\left(\frac{x_i}{w_i} \right) - \left(\frac{x_{i-1}}{w_i} \right) \right] \quad (5.9)$$

La inclusión de estos nuevos criterios permitió realizar una toma de decisiones con una mayor cantidad de información. Para probar el desempeño de la inclusión de estos criterios se tomaron como base cinco vectores con los mejores resultados de la Tabla 5.3, a los cuales se les añadió de forma aleatoria el peso e impacto para los criterios que se añadieron probando un total de 200 combinaciones de vectores de peso W e impacto I . Los resultados para los 20 pares de vectores con mejores resultados en las métricas se pueden observar en la Tabla 5.4.

Tabla 5.4 Resultados para las duplas considerando los nuevos criterios

Vector W, I	Efficiency	Comfort	LCFQI
[2,5,5,5,3,5,2],[-,+,+,+,-,-,+]	40	0.56	4.6
[3,5,5,5,4,4,2],[-,+,+,+,-,-,-]	40	0.48	4
[2,5,4,5,4,3,2],[-,+,+,+,-,-,-]	40	0.55	5
[3,5,4,5,5,4,2],[-,+,+,+,-,-,-]	40	0.46	4.8
[2,5,3,5,5,5,2],[-,+,+,+,-,-,-]	40	0.52	4.1
[3,5,3,5,4,3,2],[-,+,+,+,-,-,-]	39	0.39	4.6
[2,4,5,5,3,5,2],[-,+,+,+,-,-,-]	39	0.49	4.4
[3,4,5,5,5,5,2],[-,+,+,+,-,-,-]	39	0.45	4.4
[2,4,4,5,5,4,2],[-,+,+,+,-,-,-]	39	0.48	4.2
[3,4,4,5,5,4,2],[-,+,+,+,-,-,-]	39	0.42	3.8
[2,4,3,5,5,4,2],[-,+,+,+,-,-,-]	38	0.44	4
[3,4,3,5,4,5,2],[-,+,+,+,-,-,-]	38	0.37	3.4
[2,4,2,5,5,5,2],[-,+,+,+,-,-,-]	38	0.41	3.4
[3,4,2,5,5,4,2],[-,+,+,+,-,-,-]	38	0.34	2.6
[3,3,5,5,3,5,2],[-,+,+,+,-,-,-]	38	0.36	3
[2,3,5,5,5,4,2],[-,+,+,+,-,-,-]	37	0.32	4
[3,3,4,5,5,5,2],[-,+,+,+,-,-,-]	37	0.35	3.6
[2,3,4,5,3,5,2],[-,+,+,+,-,-,-]	37	0.35	4.1
[3,3,2,5,5,3,2],[-,+,+,+,-,-,-]	37	0.33	3.8
[2,2,4,5,4,4,2],[-,+,+,+,-,-,-]	36	0.28	3.2

La inclusión de los nuevos criterios mejora el desempeño considerablemente debido a que con los criterios anteriores el vehículo se salía del camino en algunos segmentos, especialmente con la presencia de obstáculos dinámicos como se observó en el experimento

4.4.3. Aunque en algunos casos se ve reducida la velocidad a la cual el vehículo se desplaza a lo largo del camino, esto se debe a la importancia dada a mantener la brecha de velocidad y al propio criterio de velocidad. El considerar el cambio de carril realizado por una trayectoria y la permanencia al centro del carril permite tener una conducción con mayor estabilidad dentro de un carril, lo cual directamente reduce la posibilidad de una colisión.

Los resultados de todas las combinaciones probadas en las métricas, se pueden observar en el gráfico de la Figura 5.5, en el cual se muestran los valores normalizados para los resultados obtenidos.

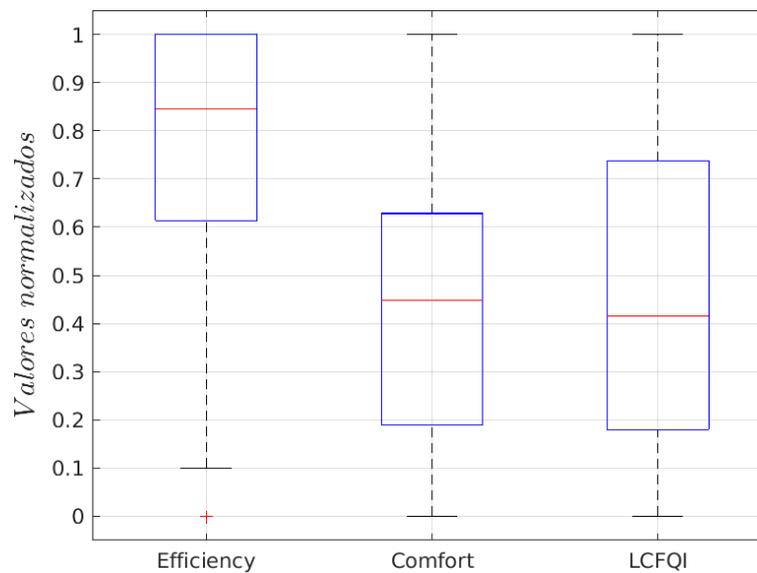


Figura 5.5 Resultados en las métricas contemplando nuevos criterios.

En el gráfico podemos observar que la eficiencia aumentó considerablemente al contemplar un mayor número de criterios, lo que le permite apegarse mejor a la geometría del camino. De igual forma el confort del vehículo aumentó debido a que se consideran los cambios de aceleración y el número de maniobras de cambio de carril, lo cual se puede apreciar además con la tendencia a la baja de la métrica LCFQI, si bien esta presenta mayor dispersión, esto se debe a los diferentes ajustes para contemplar el número de cambios de carril.

5.5.5 Experimentación con transferencia de experiencia

Si bien el ajuste fino realizado en los experimentos anteriores ha permitido obtener buenos resultados, esto debido a que se partió de una configuración inicial con buenos resultados obtenida en el experimento 5.5.3. Esto crea un problema dado que entre mayor sea el número de criterios mayor es el número de combinaciones posibles. En este caso estamos contemplando sólo siete criterios con sus respectivos siete pares de impacto y peso, esto nos da un total de $5^7 * 2^7$ combinaciones resultando en 10,000,000 de configuraciones diferentes. Realizar una búsqueda exhaustiva para cada configuración llevaría un tiempo comparable o incluso mayor al entrenamiento de un algoritmo de Aprendizaje Profundo.

Debido a las características del algoritmo TOPSIS y su enfoque difuso se decidió emplear a los vectores de peso W e impacto I como sistema de inferencia, para poder dotar al sistema de la experiencia de un conductor humano. Mediante una encuesta de catorce reactivos donde se le pregunto a treinta conductores sobre la importancia para cada criterio en una escala del 1 al 5, tomando 1 como *Muy Poco Importante*, 2 como *Poco Importante*, 3 como *Moderadamente Importante*, 4 como *Importante* y 5 como *Muy Importante*. Además se les pregunto su preferencia por *reducir* o *aumentar* dichos criterios para obtener el indicador de impacto (Apéndice A).

En total se realizaron treinta encuestas a conductores de diferentes edades, algunos con experiencia concreta en la conducción debido a sus ocupaciones, dando como contexto que la conducción sería dentro de una autopista, y se tendrían que respetar los límites de velocidad acotados para este tipo de entornos. A partir de las respuestas se construyeron los pares de vectores peso W e impacto I .

Se probó el desempeño de los vectores generados por los conductores en el escenario de la Figura 5.1, sin la presencia de obstáculos de ningún tipo, obteniendo los resultados que se muestran en la Tabla 5.5.

Tabla 5.5 Resultados de los vectores generados con la experiencia de conductores.

Vector W, I	Efficiency	Comfort	LCFQI
[3,5,2,1,4,2,1],[-,+,+,-,+,-,+]	38	0.32	4.73
[2,5,5,5,5,3,4],[+,+,+,+,-,+]	40	0.46	7.38
[5,3,4,4,5,5,4],[-,+,-,+,+,-,-]	31	0.23	3.32
[2,4,4,4,5,5,4],[-,-,-,+,-,+,-]	23	0.19	1.17
[5,5,5,4,5,5,5],[-,-,-,+,-,+,-]	20	0.12	0.18
[2,4,5,5,2,3,5],[-,+,+,+,-,+]	37	0.31	5.39
[1,5,4,2,2,3,4],[+,+,+,+,-,+]	40	0.38	6.74
[3,5,5,5,3,2,1],[+,+,+,+,-,+]	40	0.33	6.34

Resultados de los vectores generados con la experiencia de conductores (continuación).

Vector W, I	Efficiency	Comfort	LCFQI
[4,4,4,4,4,5,4],[-,+,-,+,-,+,-]	40	0.27	5.86
[3,3,2,4,4,5,2],[-,+,-,+,-,+,-]	36	0.22	4.48
[3,4,2,3,5,5,2],[-,+,+,+,-,+,-]	40	0.25	5.7
[2,2,3,4,4,5,5],[-,-,+,-,+,-]	29	0.17	2.48
[5,5,5,5,1,2,5],[+,+,+,+,+,+]	40	0.52	7.86
[3,5,4,5,3,2,5],[+,+,+,-,-,+]	40	0.49	7.62
[2,2,5,5,4,3,4],[+,-,+,-,-,+]	32	0.31	4.08
[1,4,5,4,5,5,1],[-,+,+,-,+,-,+]	31	0.23	3.32
[3,4,5,4,2,5,2],[-,+,-,+,-,+]	33	0.19	3.55
[2,2,2,2,5,5,4],[-,+,-,+,-,+]	25	0.52	3.3
[3,2,5,2,2,5,5],[-,-,+,-,+,-]	22	0.31	1.46
[1,4,5,4,2,5,4],[-,+,+,+,-,+,-]	40	0.25	5.7
[2,2,4,5,2,5,5],[-,-,+,-,+,-]	23	0.25	1.45
[3,2,5,5,2,5,2],[-,-,+,-,+,-]	24	0.13	1.12
[3,2,5,4,2,5,4],[-,+,-,+,-,+,-]	31	0.23	3.32
[4,4,5,4,4,5,2],[+,+,-,+,-,+,-]	37	0.28	5.172
[3,2,5,5,2,5,2],[+,-,+,-,+,-,+]	34	0.52	6.03
[2,2,2,2,5,5,4],[-,+,-,+,-,+,-]	25	0.52	3.3
[3,2,5,2,2,5,5],[-,-,+,-,+,-]	22	0.31	1.46
[1,4,5,4,2,5,4],[-,+,+,+,-,+,-]	40	0.25	5.7
[2,2,4,5,2,5,5],[-,-,+,-,+,-]	23	0.25	1.45
[3,2,5,5,2,5,2],[-,-,+,-,+,-]	24	0.13	1.12
[3,2,5,4,2,5,4],[-,+,-,+,-,+,-]	31	0.23	3.32
[4,4,5,4,4,5,2],[+,+,-,+,-,+,-]	37	0.28	5.172
[3,2,5,5,2,5,2],[+,-,+,-,+,-,+]	34	0.52	6.03
[1,4,5,4,4,5,5],[-,-,+,-,+,-,+]	27	0.21	2.23
[4,2,5,5,2,5,4],[+,-,-,-,-,-]	26	0.9	5.58
[3,5,5,4,2,5,4],[-,+,-,+,-,-,-]	40	0.25	5.7
[1,5,5,2,2,5,5],[+,-,+,-,+,-,+]	25	0.25	1.95
[2,2,5,4,4,5,1],[+,-,+,-,+,-,+]	29	0.34	3.47
[3,4,5,4,5,5,5],[-,+,-,+,-,-,-]	40	0.27	5.86

En los resultados podemos observar que en general los vectores obtenidos mediante la experiencia de los conductores tienden a obtener mejores resultados en ciertas métricas, esto indica la disparidad en la experiencia de los individuos encuestados o estilos de conducción diferentes. En algunos casos el confort y los cambios de carril son reducidos mientras se mantiene una velocidad relativamente baja. Existen otros individuos que alcanzaron una velocidad un poco más alta aumentando el número de maniobras pero manteniendo en un nivel óptimo el confort. Por último algunas duplas aumentaron drásticamente la velocidad y las maniobras de cambio de carril reduciendo por completo el confort de los ocupantes. Si bien en su mayoría de los casos los vehículos se mantuvieron en su carril de origen puesto que no se encontraba presente ningún tipo de obstáculo. En el caso de las duplas mencionadas anteriormente realizaron cambios de carril innecesarios en algunos casos.

Los resultados de todos los vectores obtenidos de los conductores, evaluados mediante las métricas Efficiency, Comfort y LCFQI, se pueden observar en el gráfico de la Figura 5.6, en el cual se muestran los valores normalizados para los resultados obtenidos.

En el gráfico podemos observar que la eficiencia tiene una mayor dispersión debido a las diferentes preferencias de los conductores, donde algunos le dieron mayor importancia a la velocidad máxima y a los incrementos en la aceleración. Se puede apreciar una mejora considerable en el confort dentro del vehículo, además de una menor dispersión, con algunos casos atípicos, las cruces en color rojo, donde el confort fue demasiado bajo. Para el caso de la métrica LCFQI, la dispersión es baja, lo que muestra una preferencia por realizar maniobras de cambio de carril cuando es oportuno o necesario, los valores máximos demuestran el realizar los cambios de carril de forma errática.

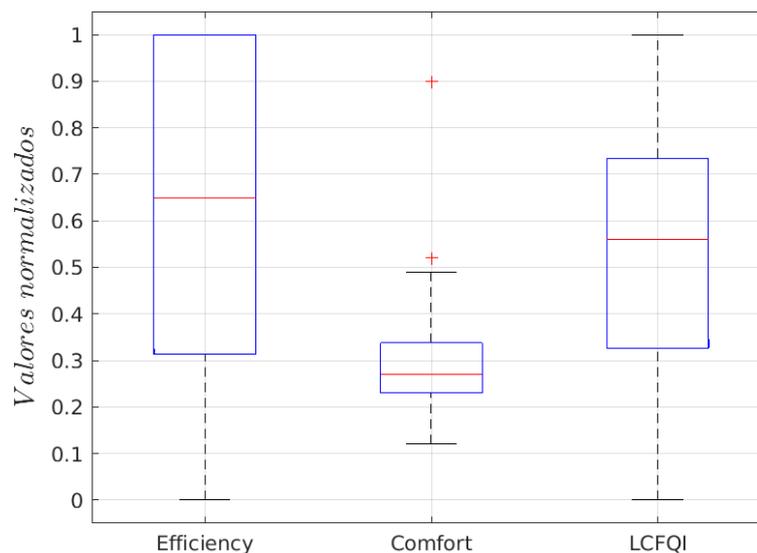


Figura 5.6 Resultados en las métricas para los vectores obtenidos de los conductores.

A partir de estos resultados se decidió agrupar estos vectores dentro de tres estilos de conducción diferentes:

- Estilo conservador: refleja a un conductor con poca experiencia, tiende a mantener una velocidad baja, no realiza maniobras complicadas y permanece en su carril a menos que sea absolutamente necesario hacer un adelantamiento.
- Estilo moderado: imita a un conductor más experimentado pero precavido, con tendencia a aumentar la velocidad pero sin realizar maniobras arriesgadas para mantener la comodidad de los pasajeros y no cambiará de carril a menos que sea necesario.
- Estilo Agresivo: tendencia a aumentar la velocidad y realizar maniobras arriesgadas sin tener en cuenta la comodidad de los ocupantes, y tenderá a cambiar de carril si hacerlo le permite avanzar a mayor velocidad.

De cada grupo se obtuvo una dupla representante, combinándolos con los vectores del experimento 5.5.4, tomando las tres con los mejores resultados, la cual se estimó obteniendo la mediana del peso y la moda del impacto para cada criterio. De esta forma se obtuvieron los vectores que se muestran la Tabla 5.6.

Tabla 5.6 Valores de los vectores W e I para cada estilo de conducción

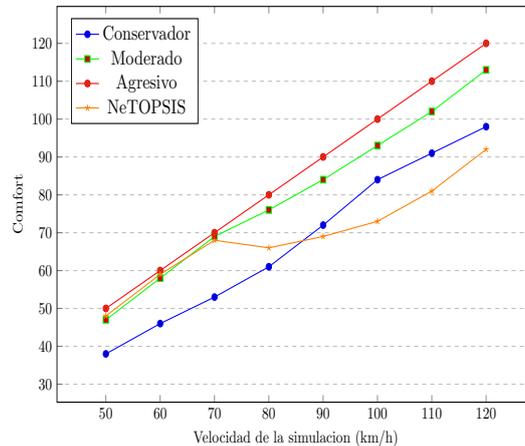
Estilo de conducción	Vectores	α	max_v	Δa	Rv_d	P_{CL}	B_d	LC
Conservador	Peso	2	4	4	3	5	5	4
	Impacto	-	-	-	+	-	+	-
Moderado	Peso	2	3	2	3	5	4	3
	Impacto	-	+	-	+	-	+	-
Agresivo	Peso	3	5	4	3	3	3	3
	Impacto	+	+	+	+	-	-	+

5.5.6 Experimentación variando los parámetros de la simulación

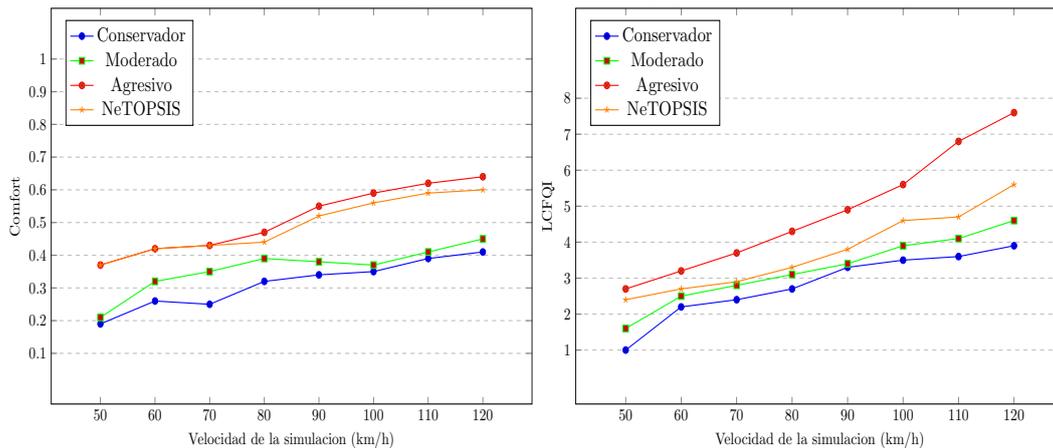
Hasta el momento a los experimentos se les asignó un límite de velocidad en la simulación, con la finalidad de mantener la estabilidad en la simulación. En este sentido el objetivo de este experimento es observar el comportamiento del esquema propuesto utilizando los diferentes vectores de impacto y peso obtenidos en el experimento anterior para observar su comportamiento al variar el límite de velocidad permitido para la simulación.

El experimento utilizó los vectores de la Tabla 5.6, así como la dupla de vectores de impacto y peso con el mejor desempeño del experimento 5.5.3, a este par se le asignó el

nombre de *NeTOPSIS*. El escenario de conducción es el de la Figura 5.1, la simulación fue sin la presencia de obstáculos y con una velocidad inicial de 50 km/h, a la que se le realizaron incrementos de 10 km/h hasta llegar a los 120 km/h. Los resultados para esta experimentación se pueden apreciar en las Figuras 5.7a-c.



(a) Resultados de Efficiency.



(b) Resultados de Comfort.

(c) Resultados de LCFQI.

Figura 5.7 Resultados para los diferentes límites de velocidad.

Los resultados muestran que a bajas velocidades los modelos parecen comportarse de manera similar a excepción del modelo *NeTOPSIS* el cual tiene un rendimiento algo menor debido a que considera sólo tres criterios, lo cual demuestra la importancia de contar con mayor información para realizar una toma de decisiones. Conforme se aumenta la velocidad podemos observar que el rendimiento de algunos modelos parece estancarse como es el caso del modelo conservador y el *NeTOPSIS*, aunque el primero mantiene un mayor confort debido a que mantiene carril y no realiza cambios de carril innecesarios. En las velocidades más altas podemos apreciar claramente que el modelo agresivo llega hasta el límite aunque sacrifica el confort de los ocupantes, mientras que el estilo moderado se mantiene con el mejor desempeño en las métricas para las velocidades altas.

5.5.7 Experimentación variando los parámetros con obstáculos estáticos

En el siguiente experimento se repitieron las mismas condiciones de velocidad del experimento 5.5.6, con la diferencia de que se incluyeron obstáculos estáticos a lo largo del camino. Los resultados de este experimento se pueden observar en las Figuras 5.8a-d.

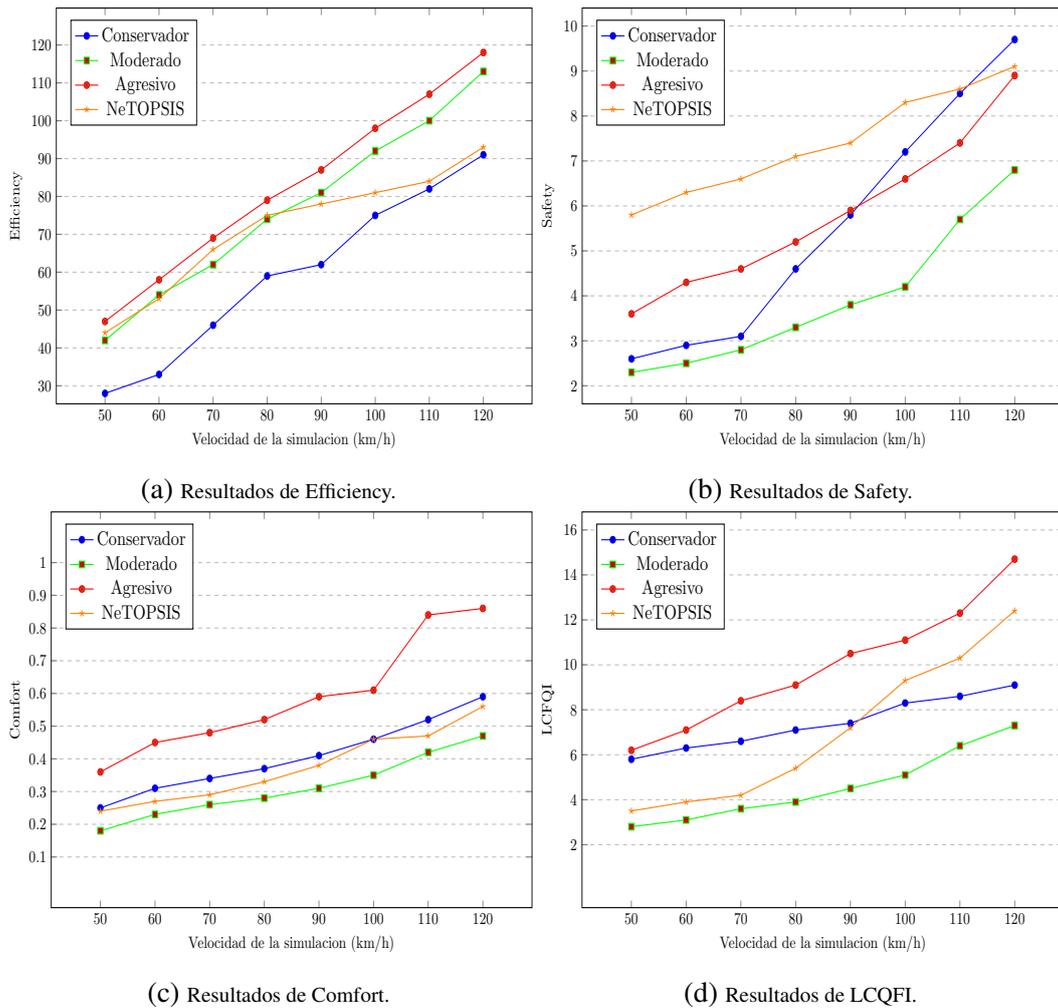


Figura 5.8 Resultados con la presencia de obstáculos estáticos.

Podemos apreciar que medida que aumenta la velocidad de la simulación, los obstáculos se vuelven más problemáticos, especialmente en los tramos curvos del camino. El modelo *NeTOPSIS* muestra el peor rendimiento, seguido del estilo agresivo, que experimenta más colisiones a medida que se acerca al límite de velocidad. El estilo moderado mantiene un buen rendimiento en la métrica de *Safety*, destacándose en particular en *Efficiency*, lo que sugiere un equilibrio entre velocidad y seguridad, típico de un conductor experimentado. Finalmente, el modelo conservador, al priorizar la seguridad y el confort, presenta la menor cantidad de colisiones.

5.5.8 Experimentación variando los parámetros con obstáculos dinámicos

Por último se repitió el experimento con las mismas condiciones y escenario del experimento 5.5.6 pero esta vez contemplando en el escenario la presencia de otros autos que viajaran a lo largo del camino, con trayectorias erráticas, algunos van más lento y sólo ocupan un carril otros realizan cambios de carril innecesarios o cruzan más de dos carriles por maniobra; para dificultar el movimiento. Los resultados se muestran en las Figuras 5.9a-d.

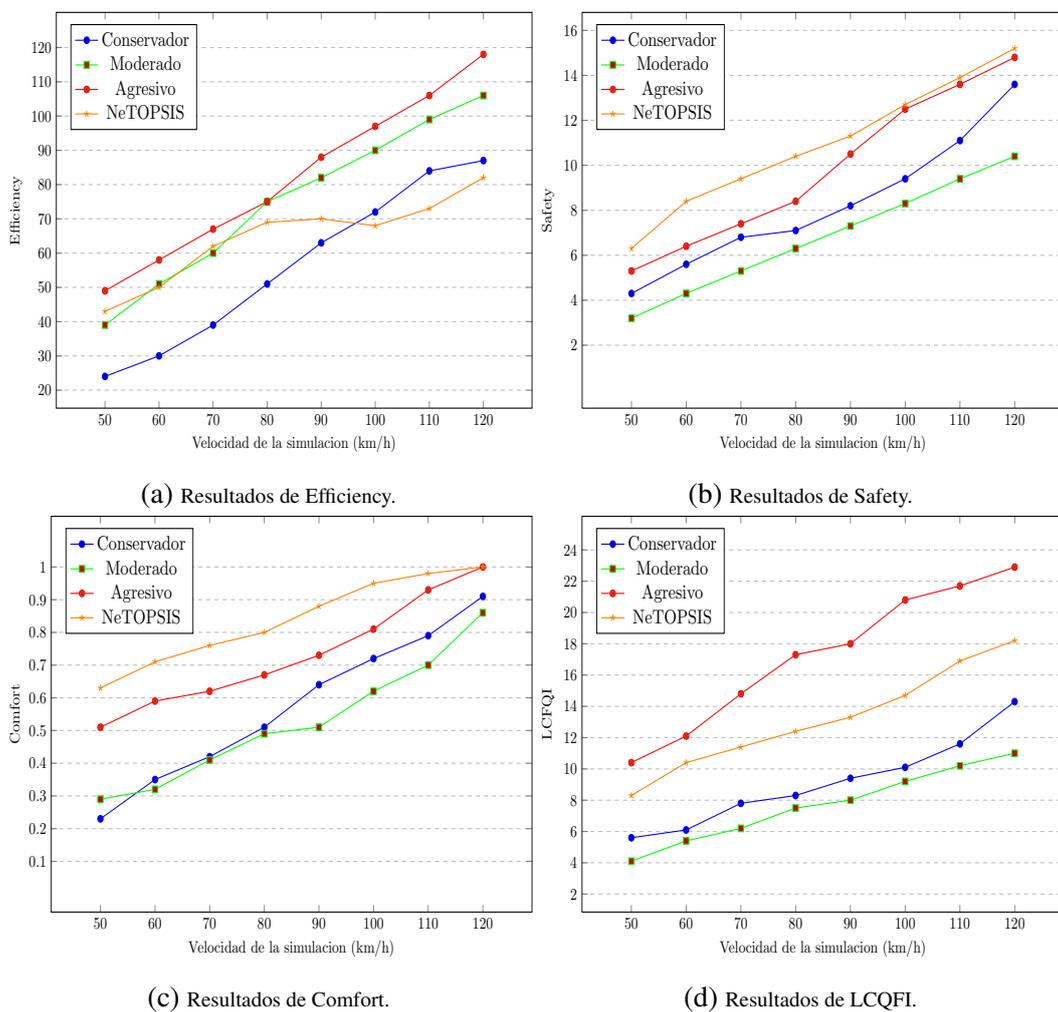


Figura 5.9 Resultados con la presencia de obstáculos dinámicos.

Los resultados muestran que el rendimiento de algunos modelos se ve afectado al aumentar la velocidad máxima de los vehículos. El modelo *NeTOPSIS* destaca con el mayor número de colisiones, que aumentan con la velocidad de la simulación. El estilo agresivo sigue una tendencia similar debido a su preferencia a cambiar de carril y aumentar la velocidad, mientras que el modelo conservador experimenta principalmente colisiones

por alcance trasero, ya que otros vehículos avanzan a una velocidad superior. El estilo moderado logra el mejor equilibrio entre las métricas al enfocarse en una conducción más estable con una velocidad aceptable.

5.5.9 Comparativa con otros métodos del estado del arte

Como parte final de las experimentaciones se realizó una comparativa entre los modelos del esquema propuesto contemplando el modelo del estilo de conducción moderado del experimento 4.4.8. Los métodos contra los que se comparó el esquema propuesto son:

- *Constrain Driven Method* (CDM): Este método evalúa cada trayectoria con restricciones de aceleración, velocidad y ángulos de dirección, si una restricción es violada la trayectoria no se toma en cuenta.
- Long Short Term Memory (LSTM): Este modelo utiliza la base de datos NGSIM [44] y genera una trayectoria para evitar colisiones [39].
- Deep Q-Learn Network (DQN). El modelo de Aprendizaje por Refuerzo fue una DQN el cual entrenó con el mismo conjunto de datos para generar políticas que determinan la toma de decisiones en carreteras [27].

La primera comparativa se realizó en el escenario de la Figura 5.1, con la presencia de obstáculos estáticos, y utilizando los siguientes límites de velocidad: 50 *km/h*, 60 *km/h*, 70 *km/h*, 80 *km/h*, 90 *km/h*, 100 *km/h*, 110 *km/h* y 120 *km/h*. Los resultados de esta comparativa se pueden apreciar en las Figuras 5.10a-d.

El rendimiento de los modelos se evaluó en función de las métricas de la sección 5.4. El modelo del estilo de conducción moderado, tiene un buen rendimiento a lo largo de todos los límites de velocidad contemplados, aunque conforme supera los 100 *km/h* se ve afectada un poco la seguridad y el confort. Para los métodos del estado del arte, el modelo CDM baja su rendimiento después de los 60 *km/h*, debido que se queda sin trayectorias disponibles debido a que las evalúa con demasiada rigidez.

En el caso de la LSTM, su rendimiento es parecido al modelo moderado, con la diferencia que sobre los 90 *km/h* empieza a verse afectado su rendimiento, debido a que este modelo genera una única trayectoria por lo tanto su tiempo de respuesta limita la velocidad máxima a la que puede viajar el vehículo. Por último el modelo DQN tiene un rendimiento similar al estilo de conducción moderado, un poco limitado en la velocidad pero con una seguridad aceptable, al ser un modelo de Aprendizaje Profundo Reforzado se entiende que su desempeño sea estable y enfocado a un estilo de conducción, dado que se entrenó en concreto para generar políticas para la toma de decisiones.

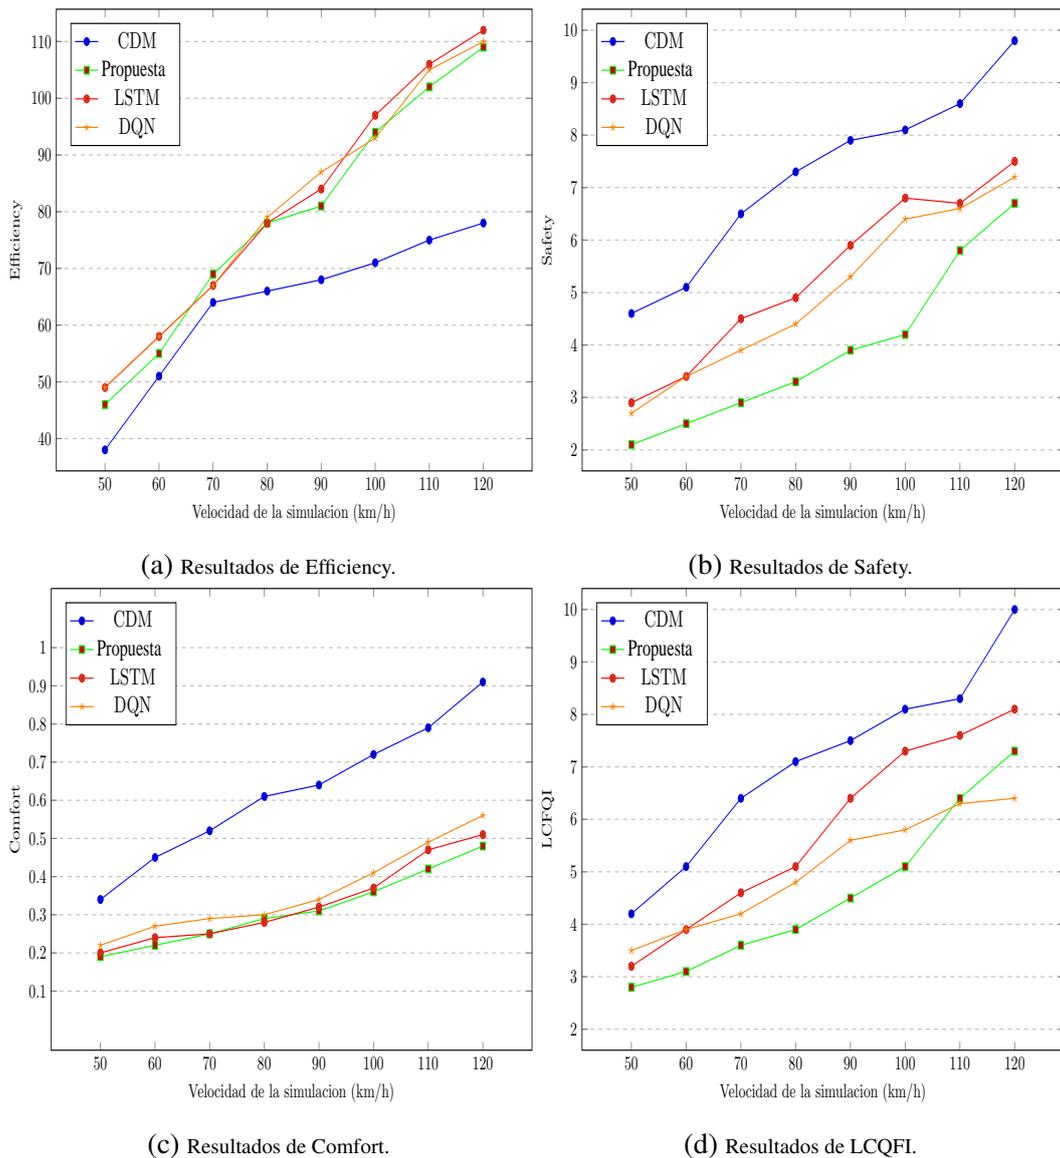


Figura 5.10 Desempeño de los modelos con obstáculos estáticos.

La segunda comparativa se realizó con los mismos parámetros de la anterior, con la diferencia que en este escenario los obstáculos eran dinámicos. Los resultados de esta comparación se pueden observar en las Figuras 5.11a-d.

En este caso los resultados reflejan claramente que la presencia de obstáculos dinámicos modifica de forma importante la dinámica de conducción, Para el caso del modelo CDM su rendimiento se estanca en los 60 km/h . El estilo moderado logra mantener un balance en las métricas debido a que este se enfoca un una conducción estable, con lo que consigue mantener su rendimiento hasta los 90 km/h , para los siguientes limites se compromete un poco la seguridad y el confort. Para el caso del modelo LSTM este mantiene su desempeño estable hasta los 70 km/h donde de igual manera tiene problemas con la seguridad y el confort. En el caso de la DQN, este mantiene su desempeño en el mismo nivel hasta

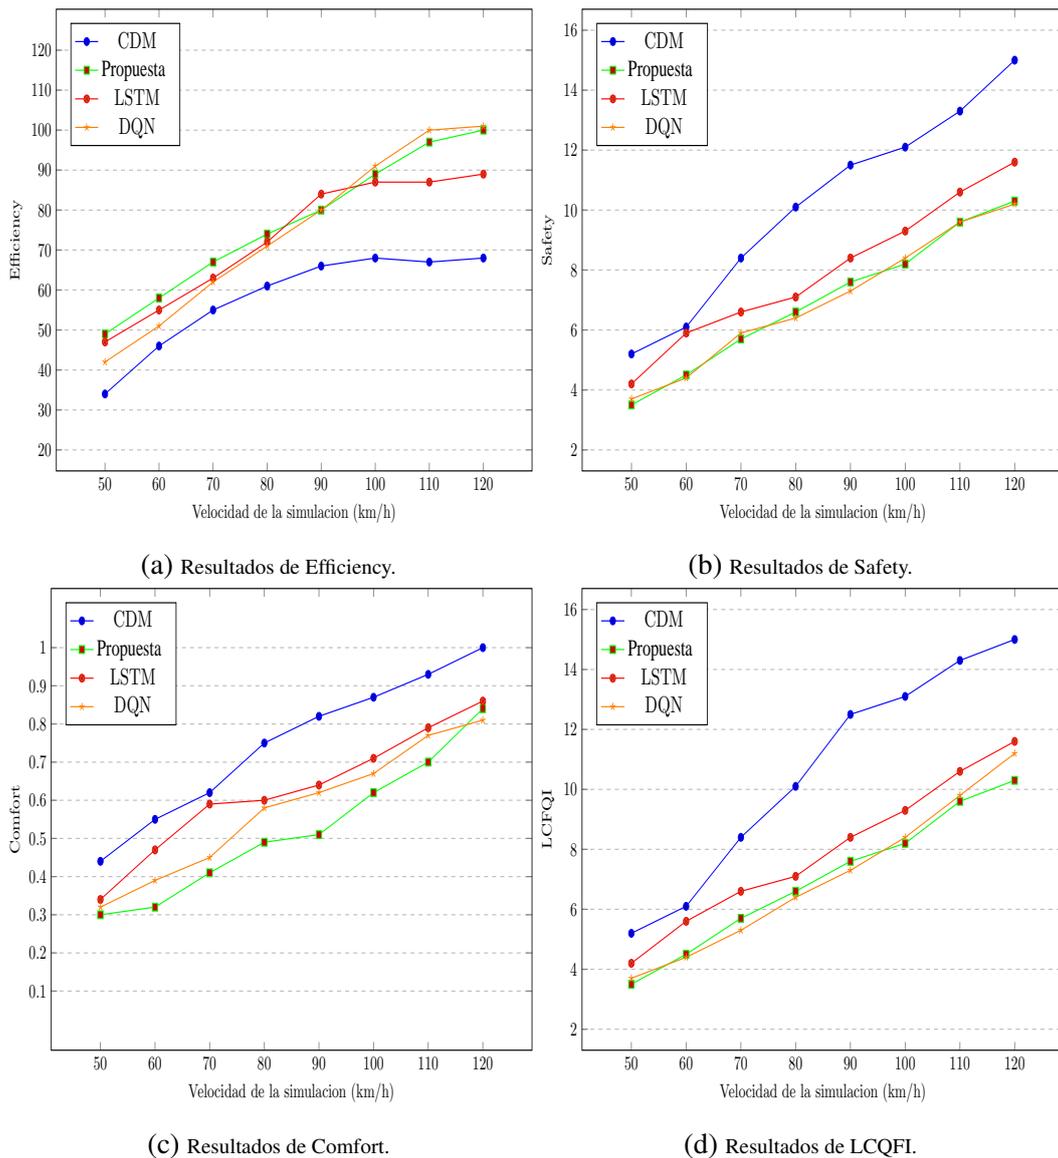


Figura 5.11 Desempeño de los modelos con obstáculos dinámicos.

los 100 km/h , después de este límite baja su rendimiento, debido posiblemente a su entrenamiento. Las condiciones en este escenario son exigentes debido a que los otros vehículos no siguen un comportamiento normal para una situación de tráfico real. De cierta forma el esquema propuesto en esta investigación es la contra propuesta a la toma de decisiones donde se aplican modelos de Aprendizaje Profundo Reforzado, con la gran diferencia que el método propuesto no requiere de grandes cantidades de datos ni etapas de entrenamiento, además de que su ajuste es mucho más sencillo, y puede mejorar sus resultados, como es el caso del estilo moderado, si se consideran los criterios adecuados y se ajustan bien los vectores de peso W e impacto I .

5.5.10 Evaluación del tiempo de respuesta

El tiempo de respuesta, en este caso el tiempo de respuesta es el tiempo que el esquema tarda en generar y evaluar el conjunto de trayectorias para obtener la trayectoria que sera la referencia del sistema de control del vehículo. No se contempla el tiempo de respuesta del modulo de control dado que no se encontraba dentro de los alcances de esta investigación. Este tiempo de respuesta puede variar según el número de criterios y número de puntos presentes en al trayectoria, dado que se realiza una compresión de la información generada en la planificación de trayectorias, a mayor número de puntos mayor es el tiempo que se tarda en realizar la compresión.

Compresión de información

El proceso comienza identificando el valor de la mediana, para la cual se requiere de un ordenamiento estadístico de los puntos que componen la trayectoria, del conjunto δ de los valores de aceleración, el cual seria el valor central. Luego, se calculan las diferencias absolutas entre cada valor y esta mediana, indicando colectivamente la extensión de la divergencia desde el centro. El promedio de estas diferencias absolutas cuantifica la dispersión general de los puntos. Para lograr un rango significativo, se establece una escala deseada de 0 a 10. Utilizando el escalado *min – max*, la diferencia absoluta promedio se transforma para ajustarse a este rango, asegurando uniformidad y facilidad de interpretación. El valor resultante se presenta como la diferencia absoluta promedio normalizada dentro de la escala elegida, y se utiliza como criterio Δa en el método TOPSIS. Para el criterio de velocidad, se obtiene el valor máximo, $\max v$, en relación con todos los valores generados en la trayectoria. Este valor también se utiliza para calcular el espacio de frenado B_d . En conjunto, estos criterios proporcionan la información necesaria para evaluar las diferentes trayectorias, asegurando seguridad y comodidad.

Con esta información podemos tener claro que en todo el esquema se realizan tres procesos en el siguiente orden:

1. Planificación de las trayectorias.
2. Compresión de la información generada.
3. Selección de la trayectoria adecuada.

En la Tabla 5.7 Podemos observar el tiempo de respuesta para cada modelo y método utilizado en los experimentos con los diferentes limites de velocidad y con o sin presencia de obstáculos.

Tabla 5.7 Tiempos de respuesta para cada modelo en diferentes condiciones.

	Velocidad	CDM	LSTM	DQN	Propuesta
Sin obstáculos	50 <i>km/h</i>	256 <i>ms</i>	224 <i>ms</i>	205 <i>ms</i>	197 <i>ms</i>
	120 <i>km/h</i>	293 <i>ms</i>	279 <i>ms</i>	238 <i>ms</i>	241 <i>ms</i>
Obstáculos estáticos	50 <i>km/h</i>	415 <i>ms</i>	290 <i>ms</i>	273 <i>ms</i>	268 <i>ms</i>
	120 <i>km/h</i>	487 <i>ms</i>	327 <i>ms</i>	319 <i>ms</i>	304 <i>ms</i>
Obstáculos dinámicos	50 <i>km/h</i>	560 <i>ms</i>	385 <i>ms</i>	340 <i>ms</i>	339 <i>ms</i>
	120 <i>km/h</i>	622 <i>ms</i>	410 <i>ms</i>	402 <i>ms</i>	390 <i>ms</i>

Como se muestra en los resultados de la Tabla 5.7 conforme se aumentó la velocidad y la presencia de obstáculos, se incrementa el tiempo de respuesta para para todos los modelos, especialmente para los modelos más básicos puesto que se empiezan a quedar sin trayectorias optimas. Es necesario mencionar que los criterios adicionales no son generados en la planificación de las trayectorias si no son derivados de la información generada en esta parte del proceso. En este caso se contempló el estilo de conducción moderado. Podemos observar que debido a su bajo costo computacional el esquema propuesto tiene tiempos de respuesta ligeramente menores a las propuestas del Aprendizaje Profundo y Aprendizaje Profundo Reforzado. Si bien hay que contemplar que en este caso se esta omitiendo una etapa de entrenamiento lo cual ya supone una enorme ventaja frente a estos métodos.

Capítulo 6

Conclusiones

Dentro de este capítulo se realiza un análisis de las conclusiones del trabajo de investigación a partir de los resultados obtenidos, mediante la experimentación realizada, en relación a los objetivos contemplados. A su vez se hace una descripción de los productos generados y las aportaciones realizadas en el tema de investigación. Para finalizar se abordan ideas y sugerencias para trabajos futuros.

6.1 Objetivos y alcances logrados

Se detallan las contribuciones al tema de la toma de decisiones en vehículos autoconducidos y al marco teórico según los objetivos específicos establecidos en la Tabla 6.1, así como los alcances y limitaciones correspondientes en la Tabla 6.2.

Tabla 6.1 Objetivos específicos.

Objetivos	Actividades
Programar un planificador de trayectorias locales considerando el espacio de Frenet.	Se realizó el desarrollo del algoritmo de planificación de trayectorias locales considerando la traslación de entidades de un sistema de referencia al espacio de Frenet.
Desarrollar un método para seleccionar la trayectoria adecuada.	Se realizó la adaptación del algoritmo TOPSIS, de su contexto original, para su aplicación en la selección de la trayectoria adecuada.
Efectuar experimentos contemplando maniobras longitudinales y laterales, con el objetivo principal de evitar accidentes viales.	Se llevaron a cabo simulaciones del método desarrollado contemplando la conducción en vías rápidas con la presencia de obstáculos estáticos y dinámicos en caminos rectos y curvos.
Evaluar el desempeño del método propuesto.	Se realizó la simulación del sistema y se evaluó su desempeño mediante métricas del estado del arte, además de realizar una comparativa con otros métodos convencionales y métodos del estado del arte.

Tabla 6.2 Alcances y Limitaciones.

Alcances	Actividades
Se contemplarán entornos controlados que representen vías rectas y curvas.	Se realizaron simulaciones contemplando vías rectas y curvas, ya sea de forma individual o combinadas en un sólo escenario
Se contemplarán obstáculos estáticos.	Se realizaron pruebas con obstáculos dinámicos (Vehículos en movimiento) que aumentaron el grado de dificultad.
Se realizará el trazado y selección de las trayectorias.	Se diseñó e implementó el algoritmo de planificación y selección de trayectorias contemplando el espacio de Frenet y la toma de decisión con múltiples criterios.
Las pruebas se efectuarán a nivel de simulación.	Se realizaron pruebas mediante el diseño y posterior simulación de escenarios con presencia de obstáculos dinámicos y con geometría del camino recta y curva.
Se experimentará con el método propuesto de selección de trayectorias.	Se realizaron experimentos con el método TOPSIS mediante el ajuste fino de los vectores de peso e impacto, la variación de la velocidad de la simulación y la inclusión de obstáculos estáticos y dinámicos.
Se contemplará el seguimiento de la trayectoria seleccionada.	Se realizó el seguimiento de las trayectorias seleccionadas mediante modelos clásicos de control.
El método de toma de decisiones contemplará 4 criterios.	Se contemplaron en total siete criterios diferentes para el algoritmo TOPSIS, además se consideraron tres estilos de conducción diferentes con sus respectivos parámetros individuales.
Limitaciones	Actividades
El método propuesto no contemplará la percepción ni el control del vehículo.	La información de percepción consistió de la posición de los vehículos circundantes, el control del vehículo se realizó mediante un método clásico de control.
Los obstáculos, ancho de vía y curva de referencia deben ser proporcionados por el sistema de percepción del vehículo.	La posición de los obstáculos se determinó mediante la comparación de estados de los vehículos. El ancho de vía y curva de referencia se determinó en el escenario.
No se contempla su funcionamiento en vías urbanas.	El método desarrollado sólo se probó en vías rápidas debido a que las vías urbanas presentan condiciones que demandan la aplicación de otros sistemas.
El modelo dinámico del vehículo, así como otras condiciones ambientales, no serán contempladas.	El modelo dinámico del vehículo se consideró para la estimación de las fuerzas g dentro del mismo, con la finalidad de medir el confort de los ocupantes. Otras condiciones adversas del clima no se consideraron puesto que son tareas del sistema de percepción.

6.2 Resultados del trabajo

6.2.1 Productos

En esta investigación se obtuvieron los siguientes productos finales:

1. Reporte del estado del arte: en este documento se presenta un resumen de las publicaciones recientes y con mayor relevancia para el desarrollo de esta investigación, considerando para su inclusión los núcleos temáticos contemplados como lo son planificación de trayectorias y toma de decisiones para la autoconducción.
2. Diseño e implementación del algoritmo de planificación y selección de trayectorias: códigos fuente para la planificación de las trayectorias a partir de una curva de referencia y su posterior selección mediante la aplicación de TOPSIS.
3. Diseño e implementación de los escenarios de simulación para el algoritmo desarrollado.
4. Póster de divulgación científica presentado en la 9ª Jornada de Ciencia y Tecnología Aplicada (Figura B.1).
5. Capítulo de libro “*TOPSIS Method for Multiple-Criteria Decision-Making Applied to Trajectory Selection for Autonomous Driving*” publicado en *Pattern Recognition* indizado en *Scopus* derivado del *Mexican Conference on Pattern Recognition (MCPR 2023)* (Figuras B.2 y B.3).
6. Artículo JCR “*Optimized TOPSIS technique for trajectory selection of self-driving vehicles on highways*” publicado en la revista *Journal of Intelligent & Fuzzy Systems* con factor de impacto 2, producto de la extensión del workshop *Cognitive Computing and Advances in Intelligent Systems*, (CCAIS-2023) (Figura B.4).
7. Documento de tesis.

6.3 Conclusiones

Los resultados obtenidos en los diferentes experimentos muestran que el sistema propuesto cumple con el objetivo principal de la investigación al obtener un desempeño favorable. De acuerdo a los experimentos llevados a cabo se demostró inicialmente que es posible alcanzar una configuración óptima de los vectores de impacto y peso mediante el ajuste fino. Sin embargo, este logro está condicionado a la limitación de criterios, ya que las combinaciones posibles aumentan exponencialmente con el número de criterios considerados.

También se evidenció la factibilidad de dotar al sistema de la experiencia de conductores humanos, aunque esto implica adaptar un estilo de conducción específico, como se ilustra en los experimentos, al incluir la experiencia se logro una mejora del 12.37 % para la métrica *Safety*, en el caso de la métrica *Efficiency* se aumento un 9.48 %, por ultimo para la métrica *Comfort* se incremento un 10 % y para *LCQFI* se redujo el 48 %, con respecto al ajuste fino. Esta adaptación resulta crucial para lograr una conducción estable y segura. Al aumentar la dificultad de los escenarios mediante la variación de parámetros, se obtuvo evidencia que respalda la idea de que la aplicación de métodos de toma de decisiones puede conferir al sistema la flexibilidad necesaria para adaptarse a diversas situaciones.

La comparativa con otros métodos del estado del arte, como el método limitado por constantes, la LSTM y DQN, revela que el desempeño del esquema propuesto es aceptable y, en algunos casos, supera a estos últimos en condiciones específicas para la métrica *Safety* se obtuvo una diferencia del 11.94 %, en el caso de la métrica *Efficiency* se obtuvo el mismo resultado, para la métricas *Comfort* se incremento un 12 % y para *LCQFI* se redujo el 10.98 %. Cabe destacar que el esquema propuesto no requiere de una etapa de entrenamiento extensa ni de grandes cantidades de datos para lograr la generalización suficiente y ser funcional en una tarea dinámica como la conducción de un vehículo. Otro punto a resaltar es la diferencia en el tiempo de respuesta entre los diferentes métodos del estado del arte y la propuesta, donde se logro reducir el tiempo de respuesta en un 4.10 % con respecto a los métodos que utilizan Aprendizaje profundo y 59.49 % para las técnicas más rudimentarias.

En resumen, el sistema propuesto obtuvo resultados de demuestran la factibilidad de utilizar métodos de toma de decisiones en este tipo de aplicaciones. Además, se demostró que es posible dotar al sistema de la experiencia de conductores humanos, donde al aumentar la dificultad de los escenarios, el sistema cuenta con la flexibilidad necesaria para adaptarse a diversas situaciones. La comparación con otros métodos del estado del arte revela que el desempeño del esquema propuesto es aceptable y, en algunos casos, supera a estos últimos en condiciones específicas.

6.4 Trabajo futuro

Como trabajo futuro derivado de esta investigación, se plantea la implementación de la metodología propuesta en un entorno de simulación especializado como lo es *BeamNG.tech*, dado que este es capaz de simular con mayor realismo las condiciones dinámicas del vehículo además de que permite emular diferentes sensores. Esto es con la finalidad de poder obtener mayor información del vehículo para considerar otros criterios y mejorar la toma de decisiones al aumentar la información disponible sobre el vehículo y su entorno.

En cuanto a la aplicación de TOPSIS, se considera que es necesario contemplar una forma de evaluar las trayectorias de forma recurrente, dado que esta técnica no este diseñada originalmente para fenómenos dinámicos, esto con la finalidad de mantener coherencia en la conducción, mediante la evaluación de los cambios de la trayectoria en todos sus puntos. De esta forma se puede lograr una conducción con mayor seguridad y suavidad.

Referencias

- [1] Aguirre, E. (2006). Geometria diferencial de curvas y superficies.
- [2] Bakioglu, G. and Atahan, A. O. (2021). Ahp integrated topsis and vikor methods with pythagorean fuzzy sets to prioritize risks in self-driving vehicles. *Applied Soft Computing*, 99:106948.
- [3] Barua, B., Gomes, C., Baghe, S., and Sisodia, J. (2019). A self-driving car implementation using computer vision for detection and navigation. *2019 International Conference on Intelligent Computing and Control Systems (ICCS)*.
- [4] Cervantes, A. P. (2023). Detección de obstáculos y planos durante el esplazamiento vehicular.
- [5] Choi, Y.-M. and Park, J.-H. (2022). Game-based lateral and longitudinal coupling control for autonomous vehicle trajectory tracking. *IEEE Access*, pages 31723–31731.
- [6] Duan, J., Eben Li, S., Guan, Y., Sun, Q., and Cheng, B. (2020). Hierarchical reinforcement learning for self-driving decision-making without reliance on labelled driving data. *IET Intelligent Transport Systems*, 14(5):297–305.
- [7] El Alaoui, M. (2021). *Fuzzy TOPSIS: logic, approaches, and case studies*. CRC press.
- [8] Farag, W. and Saleh, Z. (2019). Mpc track follower for self-driving cars.
- [9] Gao, X., Li, X., Liu, Q., Li, Z., Yang, F., and Luan, T. (2022). Multi-agent decision-making modes in uncertain interactive traffic scenarios via graph convolution-based deep reinforcement learning. *Sensors*, 22(12):4586.
- [10] Hang, P., Lv, C., Xing, Y., Huang, C., and Hu, Z. (2020). Human-like decision making for autonomous driving: A noncooperative game theoretic approach. *IEEE Transactions on Intelligent Transportation Systems*, 22(4):2076–2087.
- [11] Hoel, C.-J., Driggs-Campbell, K., Wolff, K., Laine, L., and Kochenderfer, M. J. (2019). Combining planning and deep reinforcement learning in tactical decision making for autonomous driving. *IEEE transactions on intelligent vehicles*, 5(2):294–305.
- [12] Hoel, C.-J., Wolff, K., and Laine, L. (2020). Tactical decision-making in autonomous driving by reinforcement learning with uncertainty estimation. In *2020 IEEE Intelligent Vehicles Symposium (IV)*, pages 1563–1569. IEEE.
- [13] Hoffmann, G. M., Tomlin, C. J., Montemerlo, M., and Thrun, S. (2007). Autonomous automobile trajectory tracking for off-road driving: Controller design, experimental validation and racing.
- [14] Horvath, E. and Pozna, C. R. (2021). Clothoid-based trajectory following approach for self-driving vehicles. pages 251–254. Institute of Electrical and Electronics Engineers Inc.

- [15] Huang, C., Lv, C., Hang, P., and Xing, Y. (2021). Toward safe and personalized autonomous driving: Decision-making and motion control with dpf and cdt techniques. *IEEE/ASME Transactions on Mechatronics*, 26(2):611–620.
- [16] Jeong, Y. (2021). Self-adaptive motion prediction-based proactive motion planning for autonomous driving in urban environments. *IEEE Access*, 9:105612–105626.
- [17] Ji, J., Wang, H., Ren, Y., and Khajepour, A. (2021). Path planning and tracking for vehicle collision avoidance in lateral and longitudinal motion directions. *Synthesis Lectures on Advances in Automotive Technology Synthesis Lectures on Advances in Automotive Technology*.
- [18] Kacprzyk, J. and Pedrycz, W. (2015). *Springer handbook of computational intelligence*. Springer.
- [19] Kang, L. W., Hsu, C. C., Wang, I. S., Liu, T. L., Chen, S. Y., and Chang, C. Y. (2020). Vehicle trajectory prediction based on social generative adversarial network for self-driving car applications. pages 489–492. Institute of Electrical and Electronics Engineers Inc.
- [20] Korkmaz, B., Etlik, U. B., and Aykut Beke, T. K. (2018). Fuzzy logic based self-driving racing car control system.
- [21] Lee, K., Jeon, S., Kim, H., and Kum, D. (2019). Optimal path tracking control of autonomous vehicle: Adaptive full-state linear quadratic gaussian (lqg) control. *IEEE Access*, 7:109120–109133.
- [22] Lee, U., Yoon, S., Shim, H., Vasseur, P., and Demonceaux, C. (2014). Local path planning in a complex environment for self-driving car. *IEEE International Conference on Cyber Technology in Automation, Control and Intelligent Systems*.
- [23] Li, A., Jiang, H., Li, Z., Zhou, J., and Zhou, X. (2020). Human-like trajectory planning on curved road: Learning from human drivers. *IEEE Transactions on Intelligent Transportation Systems*, 21:3388–3397.
- [24] Li, J., Chen, Y., Zhao, X. N., and Huang, J. (2022). An improved dqn path planning algorithm. *Journal of Supercomputing*, 78:616–639.
- [25] Liao, J., Liu, T., Tang, X., Mu, X., Huang, B., and Cao, D. (2020). Decision-making strategy on highway for autonomous vehicles using deep reinforcement learning. *IEEE Access*, 8:177804–177814.
- [26] Luna, A. J. A. (2020). Conducción autónoma de un vehículo simulado mediante un modelo de red neuronal convolucional recurrente.
- [27] Mohammadhasani, A., Mehrivash, H., Lynch, A., and Shu, Z. (2021). Reinforcement learning based safe decision making for highway autonomous driving. *arXiv preprint arXiv:2105.06517*.
- [28] Mohammadpour, M., Kelouwani, S., Gaudreau, M.-A., Allani, B., Zeghmi, L., Amamou, A., and Graba, M. (2022). Energy-efficient local path planning of a self-guided vehicle by considering the load position. *IEEE Access*, 10:112669–112685.

- [29] Mu, Z. and Li, Z. (2018). Intelligent tracking car path planning based on hough transform and improved pid algorithm. *International Conference on Systems and Informatics*.
- [30] Mújica, D., Vela, V., Luna, A., Rendón, A., Matuz, M., and Rubio, J. (2022). Navigation of a differential wheeled robot based on a type-2 fuzzy inference tree. *Machines*, 10(8):660.
- [31] Ni, J., Shen, K., Chen, Y., Cao, W., and Yang, S. X. (2022). An improved deep network-based scene classification method for self-driving cars. *IEEE Transactions on Instrumentation and Measurement*, 71:1–14.
- [32] Nie, X., Liang, Y., and Ohkura, K. (2023). Autonomous highway driving using reinforcement learning with safety check system based on time-to-collision. *Artificial Life and Robotics*, 28(1):158–165.
- [33] Paxton, C., Raman, V., Hager, G. D., and Kobilarov, M. (2017). Combining neural networks and tree search for task and motion planning in challenging environments.
- [34] Pucher, F. (2018). Trajectory Planning in the Frenet Space.
- [35] Radmanesh, M., Kumar, M., Guentert, P. H., and Sarim, M. (2018). Overview of path-planning and obstacle avoidance algorithms for uavs: A comparative study. *Unmanned Systems*, 6:95–118.
- [36] Rendón, C. A. A. (2020). Sistema embebido para asistencia de conducción basado en lógica difusa tipo-2.
- [37] Rojas, F. A. M. (2019). Evaluación del algoritmo theta* para planeación de trayectorias.
- [38] Serway, R. A. et al. (2015). *Física para ciencias e ingeniería*. Biblioteca Hernán Malo González.
- [39] Shi, Y., Li, Y., Fan, J., Wang, T., and Yin, T. (2020). A novel network architecture of decision-making for self-driving vehicles based on long short-term memory and grasshopper optimization algorithm. *IEEE Access*, 8:155429–155440.
- [40] Shu, K., Yu, H., Chen, X., Li, S., Chen, L., Wang, Q., Li, L., and Cao, D. (2021). Autonomous driving at intersections: A behavior-oriented critical-turning-point approach for decision making. *IEEE/ASME Transactions on Mechatronics*, 27(1):234–244.
- [41] Sorniotti, A., Barber, P., and Pinto, S. D. (2016). Path tracking for automated driving: A tutorial on control system formulations and ongoing research.
- [42] Takahama, T. and Akasaka, D. (2017). Model predictive control approach to design practical adaptive cruise control for traffic jam.
- [43] Tapp, K. (2016). *Undergraduate Texts in Mathematics Differential Geometry of Curves and Surfaces*. Springer.
- [44] Thompson, K. (2022). Next generation simulation (ngsim) vehicle trajectories and supporting data. Data set.

- [45] Troullinos, D., Chalkiadakis, G., Papamichail, I., and Papageorgiou, M. (2021). Collaborative multiagent decision making for lane-free autonomous driving. In *Proceedings of the 20th International Conference on Autonomous Agents and MultiAgent Systems*, pages 1335–1343.
- [46] Valdepeña, R. F. J. (2022). Navegación de un robot omnidireccional basada en lógica difusatipo-2.
- [47] Wang, W., Jiang, L., Lin, S., Fang, H., and Meng, Q. (2022a). Imitation learning based decision-making for autonomous vehicle control at traffic roundabouts. *Multimedia Tools and Applications*, 81(28):39873–39889.
- [48] Wang, W., Qie, T., Yang, C., Liu, W., Xiang, C., and Huang, K. (2022b). An intelligent lane-changing behavior prediction and decision-making strategy for an autonomous vehicle. *IEEE Transactions on Industrial Electronics*, 69(3):2927–2937.
- [49] Wang, X., Qi, X., Wang, P., and Yang, J. (2021a). Decision making framework for autonomous vehicles driving behavior in complex scenarios via hierarchical state machine. *Autonomous Intelligent Systems*, 1:1–12.
- [50] Wang, Z.-j., Chen, X.-m., Wang, P., Li, M.-x., Ou, Y.-j.-x., and Zhang, H. (2021b). A decision-making model for autonomous vehicles at urban intersections based on conflict resolution. *Journal of advanced transportation*, 2021:1–12.
- [51] Yin, J. and Fu, W. (2018). A hybrid path planning algorithm based on simulated annealing particle swarm for the self-driving car.
- [52] Yoneda, K., Iida, T., Kim, T. H., Yanase, R., Aldibaja, M., and Sukanuma, N. (2018). Trajectory optimization and state selection for urban automated driving. *Artificial Life and Robotics*, 23:474–480.
- [53] Yu, L., Kong, D., Shao, X., and Yan, X. (2018). A path planning and navigation control system design for driverless electric bus. *IEEE Access*, 6:53960–53975.
- [54] Zhang, S., Wu, Y., Ogai, H., Inujima, H., and Tateno, S. (2021). Tactical decision-making for autonomous driving using dueling double deep q network with double attention. *IEEE Access*, 9:151983–151992.
- [55] Zhang, S., Zhi, Y., He, R., and Li, J. (2020). Research on traffic vehicle behavior prediction method based on game theory and hmm. *IEEE Access*, 8:30210–30222.
- [56] Zhang, T., Fu, M., Song, W., Yang, Y., and Wang, M. (2022). Trajectory planning based on spatio-temporal map with collision avoidance guaranteed by safety strip. *IEEE Transactions on Intelligent Transportation Systems*, 23:1030–1043.
- [57] Zhou, Q., Shen, Z., Yong, B., Zhao, R., and Zhi, P. (2022). *Theories and practices of self-driving vehicles*. Elsevier.
- [58] Árpád Fehér, Aradi, S., and Bécsi, T. (2020). Hierarchical evasive path planning using reinforcement learning and model predictive control. *IEEE Access*, 8:187470–187482.

Apéndice A

Encuesta

Preferencias de conducción

¡Gracias por participar en nuestra Encuesta de Preferencias de Conducción! Queremos conocer tus preferencias personales en varios aspectos relacionados con la conducción para mejorar y personalizar tu experiencia. Por favor, indica tu nivel de importancia y tus preferencias para los siguientes parámetros, utilizando una escala del 1 al 5, donde 1 es "Poco Importante" y 5 es "Muy Importante". Además, indícanos si prefieres aumentar o reducir cada criterio.

No compartido

* Indica que la pregunta es obligatoria

¿Qué tan importante consideras que es contemplar el ángulo de giro al conducir? *

1 2 3 4 5

Muy Poco Importante Muy Importante

¿Consideras que se debe de reducir o incrementar este parámetro? *

Reducir

Incrementar

¿Qué tan importante consideras que es contemplar la velocidad máxima al conducir?

1 2 3 4 5

Muy Poco Importante Muy Importante

Figura A.1 Fragmento de la encuesta realizada sobre las preferencias de conducción.

Apéndice B

Producción

Se presentó un poster de divulgación científica presentado en la 9° Jornada de Ciencia y Tecnología Aplicada (Figura B.1).



Figura B.1 Constancia de la presentación del póster.

Se realizó la publicación y presentación del capítulo de libro “*TOPSIS Method for Multiple-Criteria Decision-Making Applied to Trajectory Selection for Autonomous Driving*”, en el 15° Mexican Conference on Pattern Recognition (MCPR 2023) en Tepic Nayarit, el 23 de junio de 2023 por la Coordinación de Ciencias Computacionales del Instituto Nacional de Astrofísica Óptica y Electrónica (INAOE). La Figura B.2 muestra la constancia de presentación y la Figura B.3 la primera página del artículo publicado.



Figura B.2 Constancia de ponencia.



TOPSIS Method for Multiple-Criteria Decision-Making Applied to Trajectory Selection for Autonomous Driving

Andrés Antonio Arenas Muñiz[✉], Dante Mújica Vargas[✉],
Arturo Rendon Castro[✉], and Antonio Luna Álvarez[✉]

Centro Nacional de Investigación y Desarrollo Tecnológico - CENIDET,
62594 Cuernavaca, Morelos, Mexico
{m22ce03,dante.mv}@cenidet.tecnm.mx

Abstract. An autonomous driving system performs various tasks, including perception, vehicle control, and trajectory planning. In the process of generating the various trajectories that the vehicle can take, a situation arises in which one of them must be selected. The *Decision-Making* task is complex because multiple options often have different criteria; each solution may have its own set of pros and cons. The system needs to weigh these factors and select the option that best fits the specific needs and goals of the situation. This task is carried out by constraint-driven methods, or by deep learning in conjunction with other machine learning techniques. To manage this complexity, Multiple-Criteria Decision-Making (MCDM) methods, such as the Technique for Order of Preference by Similarity to the Ideal Solution (TOPSIS), can be used to evaluate each candidate trajectory toward an ideal solution. This ensures that the selected trajectory is well-rounded and meets the system's needs. By providing decision making capability, performance can be improved to more natural and safe driving. The proposed approach has been tested in a Matlab simulation environment under a variety of conditions. Experiments showed that the proposed approach generates an average increase of 30% in speed, with 16.44% fewer maneuvers compared to other methods.

Keywords: Decision-Making · TOPSIS · MCDM · Autonomous-Driving

1 Introduction

Autonomous driving systems aim to improve the safety of passengers and other drivers through enhanced perception and trajectory planning by selecting an appropriate trajectory to avoid a collision. The trajectory selection decision process is a critical component of autonomous driving systems. To ensure the safety of passengers and other road users, the trajectory selection module must select the optimal path for the vehicle. This process involves the evaluation of multiple factors such as vehicle speed, road conditions, the presence of other vehicles,

© The Author(s), under exclusive license to Springer Nature Switzerland AG 2023
A. Y. Rodríguez-González et al. (Eds.): MCPDR 2023, LNCS 13902, pp. 1–13, 2023.
https://doi.org/10.1007/978-3-031-33783-3_28

Figura B.3 Primera pagina del capítulo de libro.

Además se realizó la publicación y presentación del artículo JCR “*Optimized TOPSIS technique for trajectory selection of self-driving vehicles on highways*” publicado en la revista *Journal of Intelligent & Fuzzy Systems* con factor de impacto 2, producto de la extensión del workshop *Cognitive Computing and Advances in Intelligent Systems*, (CCAIS-2023). La Figura B.4 muestra la primera página del artículo publicado.

Journal of Intelligent & Fuzzy Systems xx (20xx) x–xx
DOI:10.3233/JIFS-219365
IOS Press

1

Optimized TOPSIS technique for trajectory selection of self-driving vehicles on highways

Andrés Antonio Arenas Muñiz, Dante Mújica-Vargas, Arturo Rendón Castro, Antonio Luna-Álvarez and Virna V. Vela-Rincón
Tecnológico Nacional de México/CENIDET, Cuernavaca, Morelos, México

Abstract. The selection of an appropriate trajectory for self-driving vehicles involves the analysis of several criteria that describe the generated trajectories. This problem evolves into an optimization problem when it is desired to increase or decrease the values for a specific criterion. The contribution of this thesis is to explore the use and optimization of another technique for decision-making, such as TOPSIS, with a sufficiently robust method that allows the inclusion of multiple parameters and their proper optimization, incorporating human experience. The proposed approach showed significantly higher safety and comfort performance, with about 20% better efficiency and 80% fewer safety violations compared to other state-of-the-art methods, and in some cases outperforming in comfort by about 30.43%.

Keywords: Decision-making, human experience, trajectory selection, self-driving

1. Introduction

The objective of a self-driving vehicle is to travel from point A to point B in the safest and most efficient manner possible. This task involves several sub-tasks, with trajectory planning being the most crucial. Trajectory planning involves generating potential paths that the vehicle could take to avoid collisions and stay in the correct lane. Selecting the most suitable trajectory is a critical task due to the numerous options available. To make this decision, it is important to consider various criteria, including vehicle speed, road conditions, acceleration, safe braking distance, and lane keeping. Additionally, the desired trajectory must comply with traffic regulations while ensuring safety and avoiding obstacles. It is evident that the number of criteria could be expanded to make a more informed decision.

In recent years, Deep Learning has been used to approach this problem, as demonstrated in [7], to find correlations in the trajectories. [20] proposed a model to imitate human behavior in roundabouts. [14] used a classification approach to identify different scenes and determine the system’s behavior. [22] generated weights that were applied to the decision-making process. [10] aimed to use Deep Learning to create a risk-aware decision strategy for autonomous driving that minimizes expected risk.

The use of Reinforcement Learning in [13] was to generate a set of policies to support the decision-making process to avoid collisions; the same use of policies but for lane change decision-making was used in [11]. In the proposed approach of [8], different policies were generated to improve decision-making considering different situations; a framework to control longitudinal speed and steering by deciding the risk level of the situation was presented in [4]. Also in [6] the generation of policies was used for the avoidance of lane change maneuvers. In [12], the approach was to decide the high-level action as lane change and

*Corresponding author. Dante Mújica-Vargas, Tecnológico Nacional de México/CENIDET, Cuernavaca, Morelos, México.
E-mail: dante.mv@cenidet.tecnm.mx.

Figura B.4 Portada del artículo JCR.

Apéndice C

Retribución social

Se presentó un poster de divulgación científica presentado en la 9° Jornada de Ciencia y Tecnología Aplicada (Figura C.1).



Figura C.1 Constancia de la presentación del póster.

Se realizó la publicación y presentación del capítulo de libro “*TOPSIS Method for Multiple-Criteria Decision-Making Applied to Trajectory Selection for Autonomous Driving*”, en el 15° Mexican Conference on Pattern Recognition (MCPR 2023) en Tepic Nayarit, el 23 de junio de 2023 por la Coordinación de Ciencias Computacionales del Instituto Nacional de Astrofísica Óptica y Electrónica (INAOE). La Figura C.2 muestra la constancia de presentación y la Figura C.3 la primera página del artículo publicado.



Figura C.2 Constancia de ponencia.



TOPSIS Method for Multiple-Criteria Decision-Making Applied to Trajectory Selection for Autonomous Driving

Andrés Antonio Arenas Muñiz , Dante Mújica Vargas  ,
Arturo Rendon Castro , and Antonio Luna Álvarez 

Centro Nacional de Investigación y Desarrollo Tecnológico - CENIDET,
62594 Cuernavaca, Morelos, Mexico
{m22ce03,dante.mv}@cenidet.tecnm.mx

Abstract. An autonomous driving system performs various tasks, including perception, vehicle control, and trajectory planning. In the process of generating the various trajectories that the vehicle can take, a situation arises in which one of them must be selected. The *Decision-Making* task is complex because multiple options often have different criteria; each solution may have its own set of pros and cons. The system needs to weigh these factors and select the option that best fits the specific needs and goals of the situation. This task is carried out by constraint-driven methods, or by deep learning in conjunction with other machine learning techniques. To manage this complexity, Multiple-Criteria Decision-Making (MCDM) methods, such as the Technique for Order of Preference by Similarity to the Ideal Solution (TOPSIS), can be used to evaluate each candidate trajectory toward an ideal solution. This ensures that the selected trajectory is well-rounded and meets the system's needs. By providing decision making capability, performance can be improved to more natural and safe driving. The proposed approach has been tested in a Matlab simulation environment under a variety of conditions. Experiments showed that the proposed approach generates an average increase of 30% in speed, with 16.44% fewer maneuvers compared to other methods.

Keywords: Decision-Making · TOPSIS · MCDM · Autonomous-Driving

1 Introduction

Autonomous driving systems aim to improve the safety of passengers and other drivers through enhanced perception and trajectory planning by selecting an appropriate trajectory to avoid a collision. The trajectory selection decision process is a critical component of autonomous driving systems. To ensure the safety of passengers and other road users, the trajectory selection module must select the optimal path for the vehicle. This process involves the evaluation of multiple factors such as vehicle speed, road conditions, the presence of other vehicles,

© The Author(s), under exclusive license to Springer Nature Switzerland AG 2023
A. Y. Rodríguez-González et al. (Eds.): MCPDR 2023, LNCS 13902, pp. 1–13, 2023.
https://doi.org/10.1007/978-3-031-33783-3_28

Figura C.3 Primera pagina del capítulo de libro.

Además se realizó la publicación y presentación del artículo JCR “*Optimized TOPSIS technique for trajectory selection of self-driving vehicles on highways*” publicado en la revista *Journal of Intelligent & Fuzzy Systems* con factor de impacto 2, producto de la extensión del workshop *Cognitive Computing and Advances in Intelligent Systems*, (CCAIS-2023). La Figura C.4 muestra la primera página del artículo publicado.

Journal of Intelligent & Fuzzy Systems xx (20xx) x–xx
DOI:10.3233/JIFS-219365
IOS Press

1

Optimized TOPSIS technique for trajectory selection of self-driving vehicles on highways

Andrés Antonio Arenas Muñiz, Dante Mújica-Vargas, Arturo Rendón Castro, Antonio Luna-Álvarez and Virna V. Vela-Rincón
Tecnológico Nacional de México/CENIDET, Cuernavaca, Morelos, México

Abstract. The selection of an appropriate trajectory for self-driving vehicles involves the analysis of several criteria that describe the generated trajectories. This problem evolves into an optimization problem when it is desired to increase or decrease the values for a specific criterion. The contribution of this thesis is to explore the use and optimization of another technique for decision-making, such as TOPSIS, with a sufficiently robust method that allows the inclusion of multiple parameters and their proper optimization, incorporating human experience. The proposed approach showed significantly higher safety and comfort performance, with about 20% better efficiency and 80% fewer safety violations compared to other state-of-the-art methods, and in some cases outperforming in comfort by about 30.43%.

Keywords: Decision-making, human experience, trajectory selection, self-driving

1. Introduction

The objective of a self-driving vehicle is to travel from point A to point B in the safest and most efficient manner possible. This task involves several sub-tasks, with trajectory planning being the most crucial. Trajectory planning involves generating potential paths that the vehicle could take to avoid collisions and stay in the correct lane. Selecting the most suitable trajectory is a critical task due to the numerous options available. To make this decision, it is important to consider various criteria, including vehicle speed, road conditions, acceleration, safe braking distance, and lane keeping. Additionally, the desired trajectory must comply with traffic regulations while ensuring safety and avoiding obstacles. It is evident that the number of criteria could be expanded to make a more informed decision.

In recent years, Deep Learning has been used to approach this problem, as demonstrated in [7], to find correlations in the trajectories. [20] proposed a model to imitate human behavior in roundabouts. [14] used a classification approach to identify different scenes and determine the system’s behavior. [22] generated weights that were applied to the decision-making process. [10] aimed to use Deep Learning to create a risk-aware decision strategy for autonomous driving that minimizes expected risk.

The use of Reinforcement Learning in [13] was to generate a set of policies to support the decision-making process to avoid collisions; the same use of policies but for lane change decision-making was used in [11]. In the proposed approach of [8], different policies were generated to improve decision-making considering different situations; a framework to control longitudinal speed and steering by deciding the risk level of the situation was presented in [4]. Also in [6] the generation of policies was used for the avoidance of lane change maneuvers. In [12], the approach was to decide the high-level action as lane change and

*Corresponding author. Dante Mújica-Vargas, Tecnológico Nacional de México/CENIDET, Cuernavaca, Morelos, México.
E-mail: dante.mv@cenidet.tecnm.mx.

Figura C.4 Primera pagina del artículo JCR.