



UNIVERSIDAD NACIONAL DE COLOMBIA

Sistema de Toma de Decisiones Basado en Modelo para Cambios de Carril en Vehículos Autónomos

Andres Felipe Acosta Gil

Universidad Nacional de Colombia
Facultad de Minas, Departamento de Ciencias de la Computación y de la Decisión
Medellín, Colombia
2016

Sistema de toma de decisiones basado en modelo para cambios de carril en vehículos autónomos

Andres Felipe Acosta Gil

Tesis presentada como requisito parcial para optar al título de:
Magíster en Ingeniería - Ingeniería de Sistemas

Director:

Prof. Ing. Jairo José Espinosa M.Sc.Ph.D.

Co-Director:

Ing. Alejandro Márquez Ruiz M.Sc.Ph.D.

Línea de Investigación:

Línea de matemática avanzadas para el control y los sistemas dinámicos

Grupo de Investigación:

Grupo de Automática de la Universidad Nacional - GAUNAL

Universidad Nacional de Colombia

Facultad de Minas, Departamento de Ciencias de la Computación y de la Decisión

Medellín, Colombia

2016

“Pues la tierra no es ni fosfatos ni nitratos; y lo largo de la fibra del algodón no es la tierra. El carbón no es un hombre, ni la sal ni el agua ni el calcio. Es todo esto, pero es mucho más, mucho más; y la tierra es mucho más que su análisis”

John Steinbeck

Agradecimientos

Quiero agradecer a todas las personas que me brindaron su apoyo durante la realización de esta tesis. A mis amados hijo y esposa. A mi madre de quien he aprendido muchísimo y sigo aprendiendo. A mi padre y hermano quienes son mis héroes y modelos a seguir en muchos aspectos. A mis amados abuelos, quienes junto con mis tíos y primos hicieron de mi infancia algo inolvidable. A mis compañeros del Grupo de Automática de la Universidad Nacional (GAUNAL), en especial al Ingeniero Christian Portilla, experto en movilidad y control. A mi co-director quien siempre se mostró dispuesto a ayudarme y compartir sus conocimientos de manera desinteresada. Al director de esta tesis, quien ha potenciado mi pasión por la academia y la investigación. Finalmente, al proyecto de investigación Modelamiento y Control de Tráfico en la Ciudad de Medellín, en sus etapas uno y dos (Proyecto Colciencias 111856934640 contratos 941-2012 y FP44842-202-2015. Convocatorias 569 y 669).

Resumen

En las últimas décadas se ha presentado un gran incremento en la congestión de tráfico urbano tanto en grandes ciudades en países desarrollados, como en aquellos en vías de desarrollo, generando también un incremento en la tasa de accidentalidad. Con el rápido crecimiento de las tecnologías de la información, y las comunicaciones y la electrónica, los avances investigativos en la caracterización del tráfico vehicular y mejoras en la capacidad de cómputo y simulación computacional, una de las soluciones más prometedoras para enfrentar estos problemas consiste en el mejoramiento de la infraestructura de movilidad basado en el modelado matemático y la simulación de la dinámica vehicular. Por otro lado, los vehículos poseen niveles de autonomía cada vez mayores y capacidad de comunicarse con otros vehículos (comunicaciones vehículo a vehículo, V2V) y con la infraestructura de gestión de tráfico (comunicaciones vehículo a infraestructura, V2I), de manera que estas tecnologías también aportan no solo a la reducción de la congestión sino a la disminución de las tasas de accidentalidad. Los sistemas de toma de decisiones para la gestión de tráfico, los sistemas de asistencia al conductor y los vehículos autónomos permiten mejorar los tiempos de viaje, la confiabilidad y robustez para mejorar la experiencia de conducción y la seguridad. Una de las principales características de estos sistemas es que se basan en un modelo de predicción que les permite anticipar el estado de los vehículos y su entorno con el fin de reducir la congestión y prevenir accidentes, entre otros. El modelado de la dinámica de vehículos se puede dividir en modelos longitudinales, que describen el comportamiento de aceleración y frenado, y modelos laterales, los cuales describen los cambios de dirección del vehículo. Estos modelos han sido aplicados en sistemas de control enfocados en la seguridad activa, sistemas avanzados de asistencia al conductor (ADAS) y vehículos autónomos. Algunas aplicaciones incluyen el control de crucero, sistemas de alerta de desvío de carril y sistemas de evasión de obstáculos. En la actualidad también se han desarrollado diferentes aplicaciones para cambios de carril autónomos y semi-autónomos. Sin embargo, existen aún desafíos en cuanto a la inclusión de diferentes tipos de vehículos y criterios de confort para la ejecución de la maniobra en relación con características como la relación peso-potencia. En este trabajo se presenta un sistema de toma de decisiones basado en modelo para cambios de carril en vehículos autónomos que considera diferentes tipos de vehículos y modos de conducción, con el cual es posible caracterizar la trayectoria de la maniobra. Este sistema se compone de dos partes, las cuales conforman un sólo sistema de toma de decisiones: un sistema para la generación de trayectorias de cambio de carril utilizando optimización basada en un modelo de predicción y una red neuronal que utiliza estas trayectorias en un esquema de aprendizaje supervisado.

Palabras clave: Optimización basada en modelo, modelo dinámico de vehículo, aprendizaje supervisado

Abstract

In the last decades, urban traffic congestion has increased not only in big cities of developed countries, but in those of developing ones, which leads also to an increased accident rate. With the fast growing of information and communication technologies and electronics, research advances on road traffic characterization and improvements in computing capacity and simulation, one of the most promising solutions to face the congestion problem consists on the improvement of the mobility infrastructure based on mathematical modeling and simulation of vehicle dynamics. On the other hand, vehicles have increasing levels of autonomy and the capacity of communicating with others (Vehicle to Vehicle, V2V) and with the infrastructure (Vehicle to Infrastructure, V2I), so that these technologies improve not only the congestion reduction but also the rates of accidents. The decision-making systems for traffic management, driving assistance systems and autonomous vehicles allow to improve travel times and reliability, allowing a better driving experience and security. One of the main features of these systems relies in the fact that they are based on prediction models that permits to anticipate the state of vehicles and their environment with the aim of reducing congestion and prevent accidents, among others. Vehicle dynamics modeling can be divided into longitudinal models, which describe the behavior of acceleration and braking, and lateral models, which describe the direction changes of the vehicle. These models have been applied in control systems focused on active safety, advanced driving assistance systems (ADAS) and autonomous vehicles. Currently, different applications for autonomous and semi-autonomous lane changes have also been developed. However, some challenges remain in regards to the inclusion of different vehicle types and comfort criteria for the execution of the maneuver based on characteristics such as the power-to-weight ratio. In this work, a lane changing model-based decision-making system for autonomous vehicles is presented, which considers different types of vehicles and driving modes and adequately characterized the trajectory of the maneuver. This system is composed of two parts, which conform a single decision-making system: one system for generating lane changing trajectories using a prediction model-based optimization and a neural network that utilizes these trajectories in a supervised learning scheme.

Keywords: Model-based optimization, dynamic vehicle model, supervised learning

Contenido

Agradecimientos	vii
Resumen	ix
1. Introducción	2
2. Modelo dinámico del vehículo	7
2.1. Modelo “Single Track Model” lineal (STM)	7
2.2. Análisis del modelo STM lineal	10
2.2.1. Controlabilidad y observabilidad	10
2.2.2. Análisis en estado estacionario	11
2.2.3. Resultados de simulación	13
2.3. Modelo STM no lineal	13
3. Generación de trayectorias de cambio de carril	21
3.1. Problema de optimización	22
3.2. Inclusión de vehículos en el carril de destino	28
4. Aprendizaje de trayectorias de cambio de carril utilizando redes neuronales	36
4.1. Redes Neuronales	36
4.2. Diseño de la red neuronal	38
4.3. Aprendizaje mediante regresión lineal	39
4.4. Aprendizaje mediante una red neuronal prealimentada	41
4.5. Resultados	43
5. Control LQR para corrección de errores	46
5.1. Linealización del modelo del vehículo	47
5.2. Resultados	48
6. Conclusiones y recomendaciones	50
6.1. Conclusiones	50
6.2. Recomendaciones	51
Bibliografía	52

1 Introducción

En las últimas décadas se ha presentado un incremento en las tasas de motorización en las ciudades, principalmente en aquellas en países en vías de desarrollo. Este crecimiento trae consecuencias negativas en cuanto a la congestión, la contaminación y las tasas de accidentalidad. El alto número de muertes causadas por incidentes de tránsito ha hecho que la Organización Mundial de la Salud (OMS) catalogue este fenómeno como un problema de salud pública, siendo la principal causa de mortalidad entre la población joven, particularmente aquella entre los 15 y los 29 años [1]. En 2011, hubo 32000 muertes en los Estados Unidos [2], mientras que Europa tuvo una cifra similar en el mismo año, de 30700 muertes, la cual se encuentra por encima de las metas establecidas [3]. La situación es aún peor en países de ingresos bajos y medios, donde la OMS afirma que el número de muertes llega a superar el doble del de países de ingresos altos. Esto se debe tanto a la falta de esfuerzos a nivel legislativo como a características particulares de estas regiones, incluyendo el alto número de motocicletas y de medios de transporte alternativos. En América Latina, por ejemplo, el informe [4] muestra índices de crecimiento de hasta 448% en el número de motocicletas adquiridas en diferentes países. En el mismo informe, se indica que este crecimiento ha implicado un aumento en la tasa de mortalidad de motociclistas del 12.9% por año entre el 2008 y el 2010, siendo Colombia el país con más muertes por cada 100 mil habitantes (3.6), seguida por Brasil (2.9) y Paraguay (2.5).

En Colombia, de acuerdo con estudios realizados por el ministerio de transporte y el ministerio de salud a 2014 [5, 6], los accidentes de tránsito son la segunda causa de mortalidad en la población, apenas superada por las tasas de homicidio debidas al problema de la violencia. De estos estudios vale la pena resaltar los siguientes aspectos:

- El índice de muertes por cada cien mil habitantes viene creciendo desde el año 2011, con un valor de 13.33 en el año 2014
- El número de muertes totales también presenta el mismo comportamiento, con un total de 6352 muertes en el 2014, el más alto registrado entre 2005 y 2014. Los jóvenes entre los 14 y los 26 años son los más afectados
- Se encontró en 2014 el registro más alto desde 2009 en cuanto al número de lesiones, con valor de 44452

Si se comparan estos índices con el crecimiento poblacional y los datos históricos acumulados,

se encuentra que Colombia es el país donde más muertes se han presentado, superando ampliamente a los demás países de América Latina [7].

De acuerdo con la OMS, la mayoría de los accidentes de tránsito son predecibles y evitables, debido a que su principal causa son errores humanos como el exceso de velocidad, conducir ebrio, conducir distraído y no utilizar elementos de seguridad como el cinturón y el casco [2, 1]. Además, los vehículos de países en vías de desarrollo no cuentan con los requerimientos mínimos de seguridad establecidos por las Naciones Unidas. Esto se debe en buena medida a que los estándares de seguridad en estos países son laxos o inexistentes, lo cual aprovechan los fabricantes de vehículos, no solamente para “*vender viejos diseños que no cumplen con las regulaciones en otros países*”, sino también para ahorrar costos produciendo modelos que no incluyen algunas tecnologías de seguridad [1].

Por estas razones, las Naciones Unidas elaboraron la propuesta Decenio de Acción para la Seguridad Vial [8], donde se recomiendan diferentes tareas para que los gobiernos lleven a cabo con el fin de reducir los accidentes de tránsito. Dentro de estas tareas se encuentra un pilar dedicado al mejoramiento de la seguridad de los vehículos, donde se promueve la adopción de tecnologías de seguridad pasivas y activas. Las Naciones Unidas han desarrollado estándares de seguridad en tecnologías altamente efectivas para la prevención de accidentes como Control Electrónico de Estabilidad (ESC) y frenos ABS. Sin embargo, los vehículos vendidos en el 80 % de los países no cumplen con los estándares prioritarios de seguridad. Colombia avanza lentamente en este aspecto, ya que apenas en 2017 todos los vehículos importados o ensamblados deberán contar con *airbags* y frenos ABS [9]. En contraste, en Estados Unidos los sistemas ESC son obligatorios desde el año 2010 [10], los frenos ABS desde 2004 y los *airbags* desde 1998 [11].

Las tecnologías relacionadas con la seguridad de los vehículos se pueden categorizar en dos grandes grupos: sistemas de seguridad pasiva y sistemas de seguridad activa. Los primeros se caracterizan por ser sistemas que actúan una vez se produce el accidente, con el fin de minimizar los impactos sobre el conductor. Dentro de los sistemas de seguridad pasiva se encuentran elementos como los cinturones de seguridad y los *airbags*. Históricamente, las acciones encaminadas en la reducción de tasas de accidentalidad, en relación con el mejoramiento de la seguridad en los vehículos, se enfocó en los sistemas de seguridad pasiva. Por otro lado, los sistemas de seguridad activa se han venido desarrollando desde la década de los 70 [12]. A diferencia de los sistemas de seguridad pasiva, éstos permiten prevenir la ocurrencia de los accidentes, por medio de tecnologías como el ESC, frenos ABS, sistemas alerta de desvío de carril y control de cruce. Muchos de los sistemas de seguridad activa se enmarcan dentro del concepto de Sistemas Avanzados de Asistencia al Conductor (ADAS), y coinciden con avances enfocados en el desarrollo de los vehículos autónomos. De esta manera, los vehículos están pasando por una etapa de transición tecnológica, a través de la cual tendrán niveles cada vez más altos de autonomía. Al respecto, la Administración Nacional de Seguridad Vial (NHTSA) de los Estados Unidos ha descrito esta transición tecnológica de acuerdo con diferentes niveles de autonomía [13, 2], los cuales se listan a continuación:

- **Nivel 0:** Ninguna función del vehículo es autónoma, por lo cual todas las funciones son ejecutadas por el conductor.
- **Nivel 1:** Una sola función del vehículo es autónoma, por ejemplo, control de cruce, control de cambio de carril o parqueo. En este caso, el control del vehículo sigue siendo ejercido por el conductor.
- **Nivel 2:** Varias funciones del vehículo se ejecutan de manera autónoma e integrada, como por ejemplo control de cruce y control de dirección para mantener el centro del carril. Si bien hay situaciones en las cuales el conductor puede soltar el volante y los pedales, éste debe permanecer siempre atento para retomar el control.
- **Nivel 3:** La mayoría de las funciones del vehículo están automatizadas y el conductor puede enfocar su atención en otras actividades. Sin embargo, todavía existen situaciones críticas de seguridad en las cuales el conductor debe estar dispuesto a retomar el control del vehículo.
- **Nivel 4:** En este caso el vehículo es completamente autónomo y los pasajeros pueden estar concentrados en otras actividades.

Actualmente, diferentes compañías están realizando grandes inversiones en investigación y desarrollo alrededor de los vehículos autónomos, incluyendo Google, Tesla, Uber, Audi, Toyota y Nissan [13, 2]. Algunas de estas compañías cuentan con modelos comerciales con niveles de autonomía 1 y 2.

Si bien existen diferentes teorías acerca del impacto que tendrán los vehículos autónomos en el futuro en diferentes aspectos, ciertamente existe un potencial en cuanto a la reducción de las tasas de accidentalidad. Algunos estudios han proyectado reducciones de hasta un tercio en la cantidad de accidentes si se implementan tecnologías como sistemas de alerta de colisión frontal y desvío de carril, sistemas de asistencia de puntos muertos y luces adaptativas [2]. Además, los vehículos autónomos podrían transformar la percepción que tienen los ciudadanos respecto de los viajes. El propósito del viaje no influirá mucho, ya que el esfuerzo y concentración del conductor no serán requeridos, de manera que viajar no será visto tanto como una necesidad para llevar a cabo otras actividades (trabajar, ir de compras), sino una actividad de valor en sí, ya que los vehículos autónomos en conjunto con otras tecnologías como el teletrabajo, e-shopping y cada vez mejores sistemas de comunicaciones y redes inalámbricas, harán que las personas toleren tiempos de viaje mayores y dejen de percibir los viajes como una actividad indeseable [14].

Recientemente ha habido un creciente interés en el desarrollo de sistemas de seguridad activa, ADAS y vehículos autónomos. Las técnicas de optimización y el control basado en modelo, en especial el control predictivo basado en modelo (MPC), han sido utilizados con éxito en aplicaciones como la generación y el seguimiento de trayectorias [15, 16], evasión de obstáculos [17, 18, 19] y estabilización del vehículo [20, 21]. El control MPC consiste en

calcular las entradas óptimas para llevar la planta, en este caso el vehículo, a un estado deseado utilizando un modelo matemático de la misma, dentro de una ventana de tiempo determinada denominada horizonte de predicción [22]. Por medio de este modelo matemático, es posible estimar el estado del vehículo en el futuro, por lo cual se le conoce como modelo de predicción.

Los modelos de predicción para sistemas de asistencia al conductor y vehículos autónomos tienen en cuenta características como su relación peso-potencia, el centro de masa, la inercia y las fuerzas ejercidas en el contacto entre las llantas y el pavimento. Los ADAS y vehículos autónomos se componen de tres subsistemas principales: el control longitudinal o control de crucero, con el cual se busca mantener al vehículo a una distancia segura del vehículo de adelante, el sistema de control de desviación para mantener al vehículo en el centro del carril y finalmente un sistema de control de cambio de carril [23]. Los dos primeros subsistemas han sido ampliamente desarrollados en la literatura, incluyendo pruebas experimentales y prototipos. Estos sistemas se apoyan en tecnologías de radar, GPS y visión por computador para reducir el riesgo de accidentes al máximo. Sin embargo, un sistema automático para cambios de carril impone algunas dificultades como la determinación precisa del carril de destino, la identificación de brechas y la ejecución segura y cómoda de la maniobra. Algunos trabajos asumen la existencia de una trayectoria pre-establecida de la cual dependen para realizar cambios de carril. Otros sistemas asumen que el vehículo cuenta con un sistema que mantiene su velocidad constante durante la maniobra, lo cual limita la viabilidad de cambio de carril.

En la presente tesis se propone un sistema de toma de decisiones, basado en modelo, para cambios de carril en vehículos autónomos. Como lo muestra la figura **1-1**, este sistema se compone de una red neuronal entrenada bajo la supervisión de un generador de trayectorias óptimas de cambio de carril basado en un modelo no lineal de predicción del vehículo que considera parámetros importantes que caracterizan el tipo de vehículo como la masa y la potencia del motor. El sistema de generación de trayectorias de cambio de carril incluye restricciones de aceleración para caracterizar el modo de conducción, el cual también se puede relacionar con el tipo de conductor (agresivo o conservador) en aplicaciones de modelado microscópico. Las trayectorias generadas son utilizadas en un proceso de aprendizaje supervisado con una red neuronal prealimentada de dos capas, con la cual se busca simplificar el sistema de toma de decisiones. Además, el sistema incluye un controlador *Linear Quadratic Regulator* (LQR) para compensar los errores en la orientación del vehículo que se presentan en el sistema de aprendizaje. La efectividad del generador de trayectorias es demostrada mediante simulaciones en diferentes escenarios de velocidad y brechas disponibles en el carril de destino. También, se muestra el proceso de diseño y entrenamiento de la red neuronal, su desempeño y pruebas en simulación para finalmente describir el diseño del controlador LQR y mostrar cómo con éste es posible corregir los errores en la orientación del vehículo.

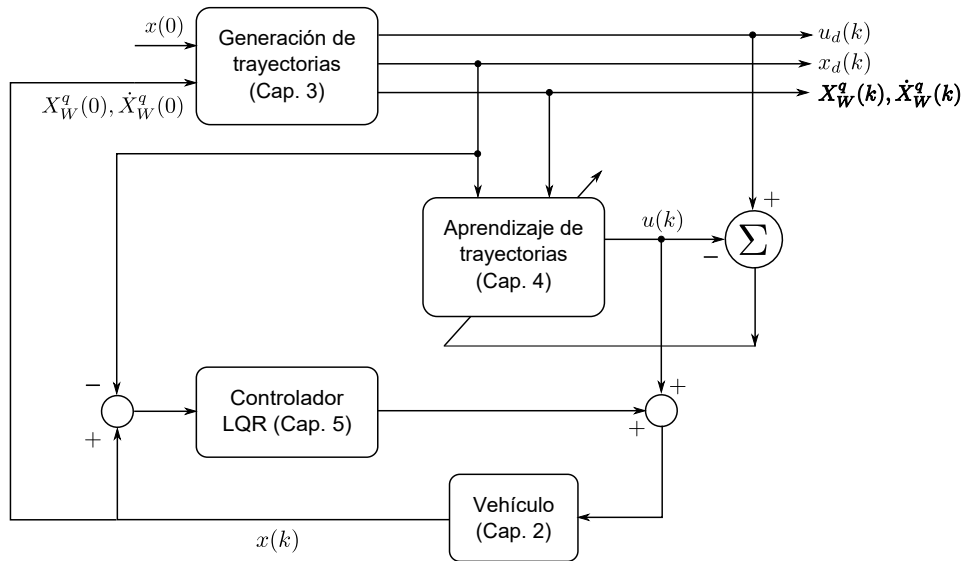


Figura 1-1: Sistema de toma de decisiones basado en modelo para cambios de carril en vehículos autónomos

Organización de la tesis

Esta tesis está organizada de la siguiente manera, con referencia a la figura **1-1**: En el capítulo 2 se presenta un modelo dinámico no lineal del vehículo, partiendo de un modelo lineal del tipo "Single Track Model". En el capítulo 3 se propone un problema de optimización basado en el modelo STM no lineal desarrollado para la generación de trayectorias de cambio de carril, incluyendo la presencia de vehículos en el carril de destino. En el capítulo 4 se propone una red neuronal para el aprendizaje supervisado de trayectorias de cambio de carril, utilizando el generador de trayectorias basado en optimización. En el capítulo 5, se presenta el diseño de un controlador LQR, utilizando un modelo lineal del vehículo para la corrección de los errores en su orientación, que se presentan en el sistema de aprendizaje de trayectorias utilizando la red neuronal. Finalmente, en el capítulo 6 se presentan las conclusiones.

2 Modelo dinámico del vehículo

Los modelos que describen el comportamiento dinámico de los vehículos de acuerdo con sus características como sus dimensiones físicas, su relación peso-potencia y su inercia, entre otras, de acuerdo con variables de entrada como el ángulo de viraje, la aceleración y el frenado, en ocasiones conocidos como modelos submicroscópicos, son modelos que en general se constituyen en un componente fenomenológico y un componente empírico. El componente fenomenológico de dichos modelos se deriva de las leyes fundamentales de conservación del momento, mientras que el componente empírico se enfoca en el modelado de las fuerzas de interacción entre las llantas y la superficie de la carretera, dada la complejidad de la estructura viscoelástica de las llantas. En este capítulo se presenta un modelo dinámico no lineal que describe el comportamiento del vehículo bajo la acción de la dirección de la rueda delantera (ángulo de viraje), la posición del acelerador y el torque de frenado. Se parte de un modelo lineal, presentado en la sección 2.1 asumiendo que el vehículo se mueve con una velocidad longitudinal constante, conocido como “Single Track Model” (STM) lateral lineal. A partir de este modelo, en la sección 2.3 se desarrolla un modelo STM no lineal el cual considera la dinámica de aceleración longitudinal del vehículo. Ambos modelos son validados mediante simulación.

2.1. Modelo “Single Track Model” lineal (STM)

Dentro de los modelos dinámicos de vehículos, uno de los más comunes, dada su simplicidad y representatividad de la dinámica lateral, es el “Single Track Model” (STM), traducido algunas veces como “Modelo de una sola línea” [24] y cuya representación se muestra en la figura 2-1. El modelo STM ha sido utilizado exitosamente en sistemas de control para vehículos, incluyendo control de aceleración y orientación, en aplicaciones como generación y seguimiento de trayectorias [15, 25], evasión de obstáculos [17] y estabilización [20].

Es importante mencionar las suposiciones principales que se tendrán en cuenta para el modelo del vehículo incluyendo aquellas que se pueden aplicar de manera general para diferentes tipos de modelos y aquellas particulares consideradas en el STM. Dentro de las primeras, se incluyen las siguientes, tomadas de [26] con algunas modificaciones:

- El vehículo es un cuerpo rígido
- No se considerará el sistema de suspensión del vehículo




Figura 2-1: Modelo “Single Track Model”

- El ángulo de dirección de las ruedas delanteras está determinado principalmente por el volante, controlado por el conductor, el ángulo correspondiente se denomina **ángulo de viraje**, conocido en el idioma inglés como “Steering angle”
- La masa de las ruedas es pequeña en comparación con la masa del vehículo
- Las ruedas tienen llantas neumáticas
- No se consideran dispositivos aerodinámicos como aletas
- El cuerpo del vehículo se caracteriza por un movimiento plano, paralelo al plano de la carretera
- El vehículo posee un diferencial abierto, lo que significa que las llantas relacionadas con la tracción del vehículo reciben ambas el mismo torque

En cuanto a la suposición principal del STM se tiene que la tasa de transmisión derecha e izquierda del sistema de dirección son casi iguales, lo cual se cumple para ángulos de viraje pequeños. Esta suposición permite que las dos ruedas delanteras se puedan representar como una sola, al igual que las ruedas traseras.

El modelo STM lineal está descrito por el modelo en espacio de estados [27] que se muestra en las ecuaciones 2-1 y 2-2.

$$\dot{x} = Ax + Bu \tag{2-1}$$

$$y = Cx + Du \tag{2-2}$$

donde los estados están dados por $x = [y', \psi, \dot{y}', \dot{\psi}]^T$. Una de las características principales que permiten que el modelo sea lineal es que está formulado en un sistema de coordenadas locales, es decir, un sistema de coordenadas fijo en el vehículo, de manera que y' es la distancia al centro instantáneo de rotación del vehículo y ψ su orientación, como se aprecia en la figura **2-1**. Nótese que se asume que la velocidad en la dirección de x' es constante en el STM, por esta razón, x' no es un estado sino un parámetro del modelo. La entrada del modelo, u corresponde con el ángulo de viraje δ el cual indica la dirección de la rueda delantera respecto del eje del vehículo. La matriz A está descrita como se muestra en la ecuación 2-3.

$$A = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & -\frac{2c_{\alpha,v} + 2c_{\alpha,h}}{m\dot{x}'} & -\dot{x}' - \frac{2c_{\alpha,v}l_v - 2c_{\alpha,h}l_h}{m\dot{x}'} \\ 0 & 0 & -\frac{2l_v c_{\alpha,v} - 2l_h c_{\alpha,h}}{\theta_{zz}\dot{x}'} & -\frac{2l_v^2 c_{\alpha,v} + 2l_h^2 c_{\alpha,h}}{\theta_{zz}\dot{x}'} \end{bmatrix} \quad (2-3)$$

donde:

- m Es la masa del vehículo
- \dot{x}' Es la velocidad en la dirección longitudinal del vehículo
- θ_{zz} Es la inercia del vehículo alrededor del eje z
- l_v, l_h Son las distancias desde el centro de gravedad del vehículo, G , al eje delantero y trasero del vehículo, respectivamente
- $c_{\alpha,v}, c_{\alpha,h}$ Son la rigidez lateral en las llantas delanteras y traseras del vehículo, respectivamente

En este punto es importante anotar que entre las principales fuerzas que se deben considerar en un modelo dinámico de vehículos se encuentran las fuerzas longitudinales y laterales que actúan sobre las llantas. En este caso, solamente se consideran las laterales ya que el vehículo se mueve a velocidad constante en el eje longitudinal. Por otro lado, en este modelo se considera un modelo lineal simplificado de la fuerza lateral que actúa sobre las llantas, el cual supone que esta fuerza es proporcional al ángulo de deslizamiento lateral del vehículo, la constante de proporcionalidad se conoce como la **rigidez lateral**. El ángulo de deslizamiento se define como el ángulo entre el vector de velocidad que actúa sobre la llanta y la orientación de la misma. Este supuesto se cumple para ángulos de deslizamiento lateral pequeños. También, se asume que el ángulo de deslizamiento del vehículo es pequeño, el cual se define, de manera similar al ángulo de deslizamiento de las llantas, como el ángulo entre el vector de velocidad que actúa sobre el centro de gravedad del vehículo y su orientación.

Finalmente, la matriz B se define como lo muestra la ecuación 2-4.

$$B = \left[0, 0, \frac{2c_{\alpha,v}}{m}, \frac{2l_v c_{\alpha,v}}{\theta_{zz}} \right]^T \quad (2-4)$$

La ecuación 2-2, conocida como modelo de medición, permite describir las variables medidas, que en el caso del modelo lineal son combinaciones lineales de los estados. La definición precisa de la ecuación de medición para el STM se describe en la sección 2.2.1.

2.2. Análisis del modelo STM lineal

A continuación se presenta un análisis de controlabilidad, observabilidad y estado estacionario del modelo STM lineal presentado en la sección anterior, con el cual se podrán identificar estrategias para el diseño de un sistema de control de cambio de carril, el cual representará un conductor que planifica una trayectoria óptima.

2.2.1. Controlabilidad y observabilidad

Un sistema dinámico, como en este caso, el modelo STM lineal descrito por las ecuaciones 2-1 y 2-2, es controlable si es posible alcanzar un estado deseado partiendo de una condición inicial, en un tiempo finito [28]. Matemáticamente, un sistema es controlable si su matriz de controlabilidad \mathcal{C} es de rango n_x , siendo n_x el número de estados. La matriz de controlabilidad se define como se indica en la ecuación 2-5.

$$\mathcal{C} = [B, AB, \dots, A^{n_x-1}B] \quad (2-5)$$

Con las matrices A y B definidas en las ecuaciones 2-3 y 2-4, respectivamente. Utilizando Matlab, es posible encontrar fácilmente que el modelo STM lineal es controlable, utilizando el comando que se muestra a continuación:

```
rankC = rank(ctrb(A,B),1e-60)
```

```
rankC =
```

```
4
```

Se concluye entonces que el STM lineal es controlable.

Por otro lado, un sistema es observable si para un número N finito, es posible conocer la condición inicial $x(0)$ a partir de las salidas (mediciones) $y(0), y(1), \dots, y(N-1)$ [28]. De manera similar a la controlabilidad, un sistema es observable si su matriz de observabilidad \mathcal{O} tiene rango n_x . La matriz de observabilidad se define como se muestra en la ecuación 2-6.

$$\mathcal{O} = [C, CA^2, \dots, CA^{N-1}]^T \quad (2-6)$$

Es fácil identificar que, si es posible medir los estados y' y ψ , entonces el sistema es observable. Por lo tanto, es posible definir la matriz C de la ecuación de medición del STM lineal 2-2 como se indica en la ecuación 2-7. Finalmente $D = [0, 0]^T$.

$$C = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} \quad (2-7)$$

La siguiente lista de código muestra el resultado del cálculo del rango de la matriz de observabilidad utilizando las matrices C y D definidas anteriormente.

```
rank0 = rank(observ(A,C),1e-60)
```

```
rank0 =
```

```
4
```

2.2.2. Análisis en estado estacionario

Un primer paso para la validación del STM lineal consiste en probar su comportamiento en estado estacionario, el cual consiste en aplicar una entrada δ_{ss} con la cual el vehículo describe una trayectoria casi circular (no perfectamente circular debido a los errores de estado estacionario, como se mostrará en breve), donde los estados y' y ψ alcanzan un valor constante [26]. La deducción matemática del comportamiento en estado estacionario parte de la definición de los errores en la posición lateral del vehículo e_1 y su orientación respecto del carril e_2 [27], considerando que éste describe una trayectoria circular de radio R , como se indica en las ecuaciones

$$\ddot{e}_1 = \ddot{y}' + \dot{x}'(\dot{\psi} - \dot{\psi}_{des}) \quad (2-8)$$

$$e_2 = \psi - \psi_{des} \quad (2-9)$$

donde:

$$\psi_{des} = \frac{\dot{x}'}{R} \quad (2-10)$$

Es la tasa de cambio en la orientación del vehículo requerida para describir la trayectoria circular. Además, si \dot{x}' es constante, también se cumple:

$$\begin{aligned} \dot{e}_1 &= \dot{y}' + \dot{x}'(\psi - \psi_{des}) \\ &= \dot{y}' + \dot{x}'\left(\psi - \frac{\dot{x}'}{R}\right) \end{aligned} \quad (2-11)$$

En [27] se planteó el modelo STM lineal en términos de las variables de estado e_1 y e_2 y utilizando una retroalimentación de estados con compensación se encontró, por medio del teorema del valor final, que los valores de estado estacionario para e_2 y δ son:

$$e_{2_{ss}} = -\frac{l_h}{R} + \frac{l_v}{2c_{\alpha,h}L} \frac{m\dot{x}'^2}{r} \quad (2-12)$$

$$\delta_{ss} = \frac{L}{R} + K_V \frac{\dot{x}'^2}{R} \quad (2-13)$$

donde $L = l_v + l_h$ y K_V es conocido como el gradiente de subviraje, definido como:

$$K_V = \frac{l_h m}{2c_{\alpha,v}L} - \frac{l_v m}{2c_{\alpha,h}L} \quad (2-14)$$

De acuerdo con la ecuación 2-9, también se debe cumplir que:

$$e_{2_{ss}} = \psi_{ss} - \frac{\dot{x}'}{R} \quad (2-15)$$

De 2-12 y 2-15, se obtiene:

$$\psi_{ss} = -\frac{l_h}{R} + \frac{\dot{x}'}{R} \left(\frac{l_h m \dot{x}'}{2c_{\alpha,h}L} + 1 \right) \quad (2-16)$$

De la misma forma, en estado estacionario, se debe cumplir en la ecuación 2-11 la siguiente condición:

$$\dot{e}_1 = 0 = \dot{y}'_{ss} + \dot{x}' \left(\psi_{ss} - \frac{\dot{x}'}{R} \right) \quad (2-17)$$

Donde, reemplazando la ecuación 2-16, se encuentra:

$$\dot{y}'_{ss} = -\frac{\dot{x}'}{R} + \left(-l_h + \frac{\dot{x}'^2 l_v m}{2c_{\alpha,h}L} \right) \quad (2-18)$$

Finalmente, mediante un análisis similar, es posible demostrar que:

$$\dot{\psi}_{ss} = \frac{\dot{x}'}{R} \quad (2-19)$$

2.2.3. Resultados de simulación

El modelo STM lineal se implementó en Matlab[®]/Simulink[®] para verificar su comportamiento en estado estacionario, mediante una simulación en lazo abierto. Se tomó una trayectoria circular de radio $R = 80$ m y una velocidad longitudinal $\dot{x}' = 20$ m s⁻¹. Reemplazando estos valores en la ecuación 2-13, se obtiene $\delta_{ss} = 0.0425$ rad. Se utilizaron los parámetros del vehículo que se encuentran en [27], los cuales se muestran en la tabla 2-1.

Parámetro	Valor	Unidades
m	1573	kg
θ_{zz}	2873	kg m ⁻²
l_v	1.10	m
l_h	1.58	m
$c_{\alpha,v}$	80000	N
$c_{\alpha,h}$	80000	N

Tabla 2-1: Parámetros para la simulación en lazo abierto

Con esta información es posible obtener los valores de los estados \dot{y}' y $\dot{\psi}$ en estado estacionario, de acuerdo con las ecuaciones 2-18 y 2-19. De esta manera, se encontró que $\dot{y}'_{ss} = -0.0085$ m s⁻¹ y $\dot{\psi}_{ss} = 0.25$ rad s⁻¹.

Para obtener la trayectoria del vehículo en coordenadas globales, se utilizan las relaciones dadas por las ecuaciones 2-20 y 2-21 [25].

$$\dot{X}_W = \dot{x}' \cos(\psi) - \dot{y}' \sin(\psi) \quad (2-20)$$

$$\dot{Y}_W = \dot{x}' \sin(\psi) + \dot{y}' \cos(\psi) \quad (2-21)$$

La figura 2-2a muestra la entrada δ_{ss} , con la cual se obtuvo la trayectoria que mostrada en la figura 2-2b, como se esperaba, se trata de una circunferencia aproximadamente de radio $R = 80$ m. Finalmente, las figuras 2-2a y 2-3b muestran los estados \dot{y}' y $\dot{\psi}$, cuyos valores en estado estacionario coinciden con los hallados analíticamente por medio de las ecuaciones 2-18 y 2-19.

2.3. Modelo STM no lineal

En la sección 2.1 se realizó una primera aproximación a un modelo dinámico de vehículo que representa su comportamiento lateral de acuerdo con el ángulo de viraje. Sin embargo, la principal desventaja del STM lineal es que, debido a que está formulado en un sistema de coordenadas fijo en el vehículo, es complicado especificar valores de referencia que se encuentren en un sistema de coordenadas global, como lo es la ubicación del carril de destino.

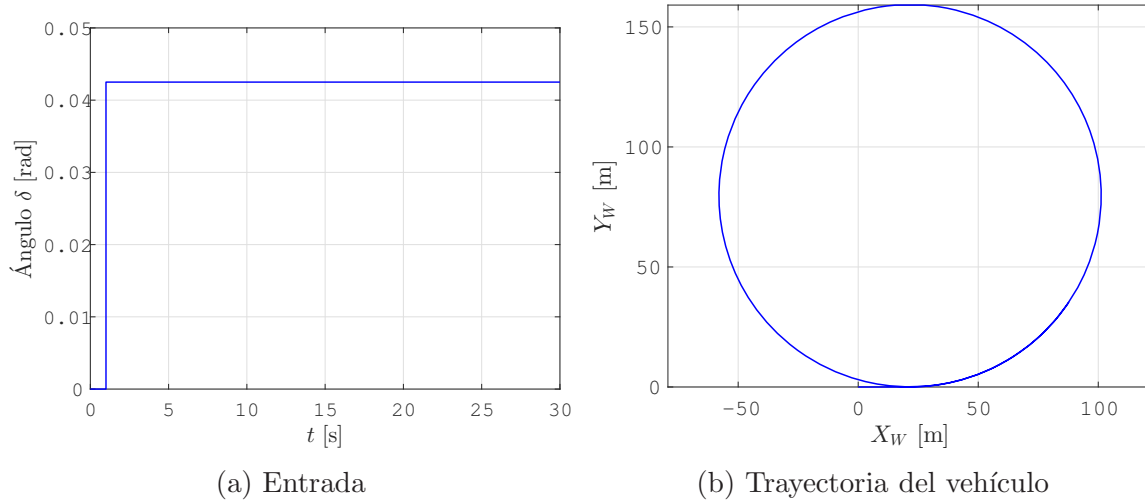


Figura 2-2: Resultados de simulación del STM lineal en estado estacionario




Figura 2-3: Resultados de simulación del STM lineal en estado estacionario

Adicionalmente, el STM lineal asume que la velocidad del vehículo es una constante, lo cual difícilmente se puede encontrar en la realidad, más aún para los propósitos del presente trabajo, es decir la caracterización de maniobras de cambio de carril. Por esta razón, en esta sección se presenta un modelo lateral no lineal incluyendo las variables de ubicación del vehículo en coordenadas globales como estados y su dinámica longitudinal.

Teniendo en cuenta las ecuaciones del modelo STM lineal dadas por 2-1 y 2-2, e incorporando las ecuaciones de transformación al sistema de referencia global dadas por 2-20 y 2-21, más las posición y velocidad longitudinal del vehículo, se puede obtener un modelo STM no lineal de la forma:

$$\dot{x} = f(x, u) \quad (2-22)$$

$$y = g(x, u) \quad (2-23)$$

En este caso, el vector de estados es:

$$x = [x', y', \psi, \dot{x}', \dot{y}', \dot{\psi}, X_W, Y_W]^T \quad (2-24)$$

El sistema de ecuaciones diferenciales, considerando la conservación del momento lineal en el eje x' para la dinámica longitudinal, es:

$$\begin{aligned} \ddot{x}' &= \frac{1}{m}(F_{v,x} + F_{h,x} - F_{W,x}) \\ \ddot{y}' &= -\frac{2c_{\alpha,v} + 2c_{\alpha,h}}{m\dot{x}'}\dot{y}' - \left(\dot{x}' + \frac{2c_{\alpha,v}l_v - 2c_{\alpha,h}l_h}{m\dot{x}'}\right)\dot{\psi} + \frac{2c_{\alpha,v}}{m}\delta \\ \ddot{\psi} &= -\frac{2l_v c_{\alpha,v} - 2l_h c_{\alpha,h}}{\theta_{zz}\dot{x}'}\dot{y}' - \frac{2l_v^2 c_{\alpha,v} + 2l_h^2 c_{\alpha,h}}{\theta_{zz}\dot{x}'}\dot{\psi} + \frac{2l_v c_{\alpha,v}}{\theta_{zz}}\delta \\ \dot{X}_W &= \dot{x}' \cos(\psi) - \dot{y}' \sin(\psi) \\ \dot{Y}_W &= \dot{x}' \sin(\psi) + \dot{y}' \cos(\psi) \end{aligned} \quad (2-25)$$

La dinámica longitudinal del vehículo está basada en el trabajo realizado por Schram, Hiller y Bardini [29], asumiendo que las llantas se encuentran en equilibrio rotacional. $F_{v,x}$ y $F_{h,x}$ son las fuerzas que producen las llantas delanteras y traseras sobre el vehículo, las cuales se explicarán en breve. Adicionalmente, $F_{W,x}$ es la fuerza debida a la resistencia del viento, la cual se define como [29]:

$$F_{W,x} = \frac{1}{2}c_w\rho_L A\dot{x}'\sqrt{\dot{x}'^2 + \dot{y}'^2} \quad (2-26)$$

donde:

- c_w (adimensional), es el coeficiente de resistencia del aire
- ρ_L (kg m^{-3}), es la densidad del aire
- A (m^2), es el área transversal máxima del vehículo

Las fuerzas $F_{v,x}$ y $F_{h,x}$ se obtienen mediante la proyección de las fuerzas resultantes de la conservación del momento en las ruedas delantera y trasera sobre el centro de masa del vehículo. Se asume que las ruedas están en equilibrio rotacional, lo cual significa que se ignora

el deslizamiento longitudinal de las llantas. Así, se encuentran las siguientes expresiones para las fuerzas $F_{v,x}$ y $F_{h,x}$:

$${}^v F_{v,x} = -\frac{1}{r} M_{B,v} \frac{\dot{\rho}_v}{|\dot{\rho}_v|} \quad (2-27)$$

$${}^h F_{h,x} = \frac{1}{r} \left(M_{A,h} - M_{B,h} \frac{\dot{\rho}_h}{|\dot{\rho}_h|} \right) \quad (2-28)$$

donde el superíndice en la espalda de la fuerza denota el sistema de referencia de la rueda (v para la rueda delantera y h para la rueda trasera). Además:

- $M_{B,v}, M_{B,h}$ Son los torques de frenado en las ruedas delantera y trasera, respectivamente
- $M_{A,h}$ Es el torque producido por el motor en la rueda trasera. Nótese que se asume un vehículo de tracción trasera, razón por la cual no hay un término $M_{A,v}$ en la ecuación 2-27
- $\dot{\rho}_v, \dot{\rho}_h$ Son las velocidades angulares de las ruedas delantera y trasera, respectivamente

Al proyectar estas fuerzas sobre el centro de masa del vehículo, se obtiene:

$$F_{v,x} = \cos(\psi + \delta) {}^v F_{v,x} \quad (2-29)$$

$$F_{h,x} = \cos(\psi) {}^h F_{h,x} \quad (2-30)$$

Nótese que en estas fuerzas longitudinales se asume que el ángulo de deslizamiento lateral es despreciable y por lo tanto, la contribución de las fuerzas laterales también lo es, dado que se asume que éstas son proporcionales a los ángulos de deslizamiento, como explicó en la sección 2.1.

Respecto de los torques producidos por la aceleración y el frenado, se asume que este último entra directamente en el modelo, aunque es posible utilizar un modelo de primer orden [30]. Este torque de frenado, M_B , se distribuye hacia la rueda delantera y la trasera con factores de $2/3$ y $1/3$ [31], respectivamente, como se muestra a continuación:

$$M_{B,v} = \frac{2}{3} M_B \quad (2-31)$$

$$M_{B,h} = \frac{1}{3} M_B \quad (2-32)$$

Por otro lado, para obtener el torque de aceleración, se aproxima el torque producido por el motor como:

$$M_M = \frac{p_f}{100} \frac{F_M}{\omega_M} \quad (2-33)$$

De esta manera, el torque producido por el motor depende de su velocidad de rotación ω_M , y un porcentaje p_f que indica en qué posición se encuentra el pedal del acelerador, el cual corresponde con una nueva entrada junto con el torque de frenado. Por lo tanto, el vector de entradas u del modelo STM no lineal es:

$$u = [\delta, p_f, M_B]^T \quad (2-34)$$

Adicionalmente, la velocidad de rotación del motor ω_M se aproxima como se muestra a continuación [29]:

$$\omega_M = i_D i_G \dot{\rho}_h \quad (2-35)$$

donde i_D es el coeficiente que representa la tasa de transmisión total del sistema de transmisión e i_G es el coeficiente de transmisión de la caja de cambios, que en este caso se asume como constante. Seguidamente, el torque total en la rueda trasera se obtiene de la siguiente manera:

$$M_{A,h} = i_D i_G M_M(\omega_M, p_f) \quad (2-36)$$

Finalmente, se supondrá que es posible medir directamente los estados Y_W y \dot{x}' para asignar correctamente valores de referencia para el cambio de carril, lo cual es posible en la actualidad gracias a los modernos sistemas GPS. De esta manera, la ecuación 3-2 resulta en:

$$y = [Y_W, \dot{x}']^T \quad (2-37)$$

Resultados de simulación

El modelo no lineal presentado en esta sección fue simulado utilizando Matlab[®] y Simulink[®] y comparado con el modelo del ejemplo de Matlab “Modeling an Automatic Transmission Controller” [32]. Esta comparación no se hizo con el propósito de que el modelo se ajuste lo mejor posible al del ejemplo de Matlab, ya que incluso poseen parámetros diferentes, sino para validar que el modelo se comporte correctamente. Se tuvieron en cuenta cuatro experimentos: posición del acelerador constante, aceleración gradual (posición del acelerador tipo rampa), movimiento por inercia y frenado. Para estas simulaciones se utilizaron los parámetros que se muestran en la tabla **2-2**, tomados de [30] más los utilizados para el modelo STM lineal (tabla **2-1**). La potencia del motor P_M equivale a 160 hp.

Adicionalmente, las condiciones iniciales para estos experimentos fueron las que se muestran a continuación:

$$x_0 = [0, 0, 0, 0.01, 0, 0, 0, 0]^T \quad (2-38)$$

Parámetro	Valor	Unidades
c_w	0.4	-
ρ_L	1.29	kg m ⁻³
A	1.8	m ²
r	0.3	m
P_M	119312	W
i_D	3.42	-
i_G	0.829	-

Tabla 2-2: Parámetros para la simulación en lazo abierto




Figura 2-4: Resultados para diferentes entradas constantes

La condición inicial de velocidad $\dot{x}'_0 = 0.01 \text{ m s}^{-1}$ indica que no es posible inicializar la velocidad con el vehículo completamente detenido, ya que se presentaría una indeterminación en la ecuación 2-36. Más aún, en [29] se indica que para el modelo con deslizamiento longitudinal son necesarias consideraciones adicionales para velocidades bajas, razón por la cual no se incluyó este deslizamiento en el presente trabajo.

La figura 2-4 muestra los resultados obtenidos con diferentes valores constantes en la posición del acelerador, se puede observar que se alcanzan diferentes velocidades en el equilibrio, siendo la máxima velocidad de 230 km h^{-1} . En la figura 2-5, se muestra la comparación de algunas de estas entradas constantes con el ejemplo de Matlab “Modeling an Automatic Transmission Controller” [32], enfocadas en el rango de velocidad de interés en un entorno urbano, es decir entre los 0 km h^{-1} y los 60 km h^{-1} . Se pudo verificar que para valores de p_f por debajo de 30, la velocidad del vehículo con el modelo STM propuesto comienza a tener una diferencia mayor respecto de la velocidad obtenida por medio del ejemplo de Matlab, debido a que no se consideraron comportamientos como la curva del motor y las diferentes tasas de transmisión producto de la caja de cambios. Sin embargo, una posición constante en el acelerador es una situación poco frecuente en la conducción y particularmente en una

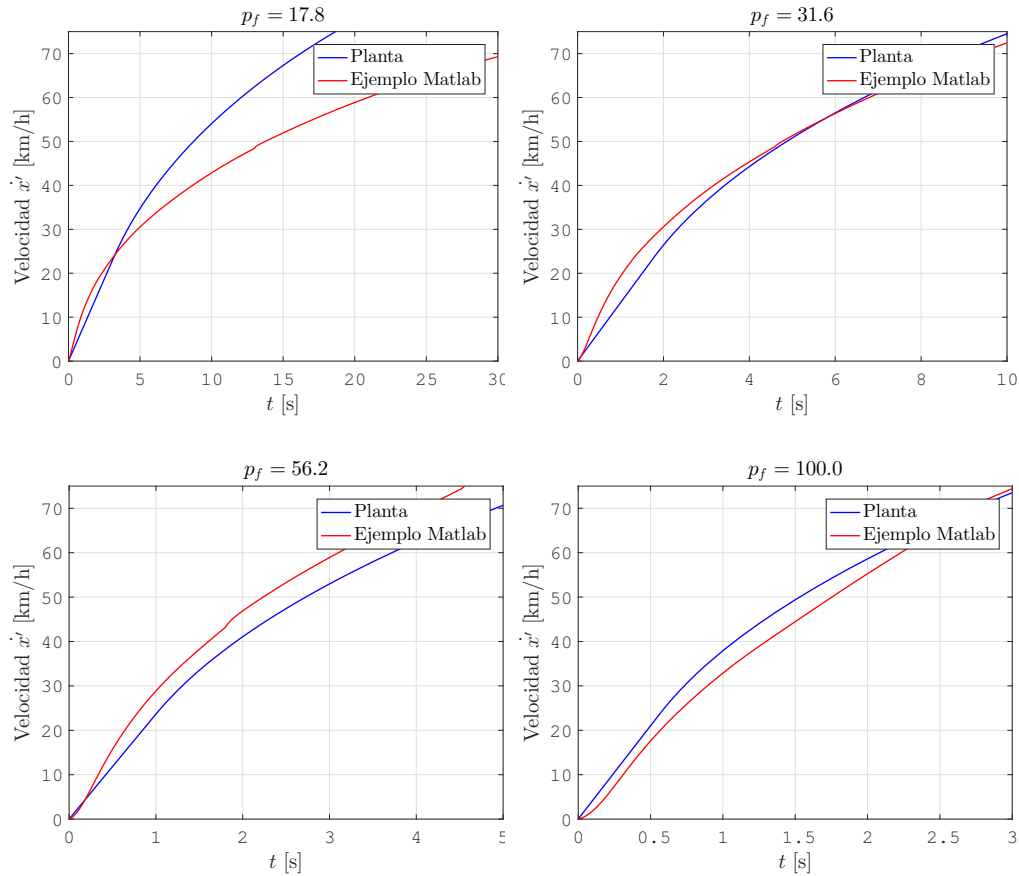


Figura 2-5: Resultados de simulación para entrada constante en comparación con el ejemplo de Matlab “Modeling an Automatic Transmission Controller” [32]

maniobra de cambio de carril. Por este motivo, se realizaron también pruebas con un perfil de aceleración considerando la posición del acelerador como una función rampa. La figura 2-6 muestra los resultados obtenidos en este caso. Obsérvese que la entrada se satura alrededor de los 330s ya que no es posible superar el 100% en la posición del acelerador. En este caso, el vehículo alcanza su máxima velocidad alrededor de los 400s y la velocidad presenta un comportamiento similar respecto de la velocidad obtenida con el ejemplo de Matlab.

La figura 2-7 muestra los resultados para el experimento de movimiento por inercia. Nótese cómo el vehículo desacelera por la resistencia del viento cuando se suelta el acelerador en $t = 5$ s. Finalmente, la figura 2-8 muestra los resultados obtenidos para el experimento de frenado. En este caso, se empleó la misma posición del acelerador que la del experimento de movimiento por inercia y además se aplicó un torque de frenado en $t = 10$ s, de manera que el vehículo desacelera por la resistencia del viento entre los 5 y los 10 segundos y luego desacelera hasta detenerse por la acción del freno.




Figura 2-6: Resultados de simulación para la entrada tipo rampa

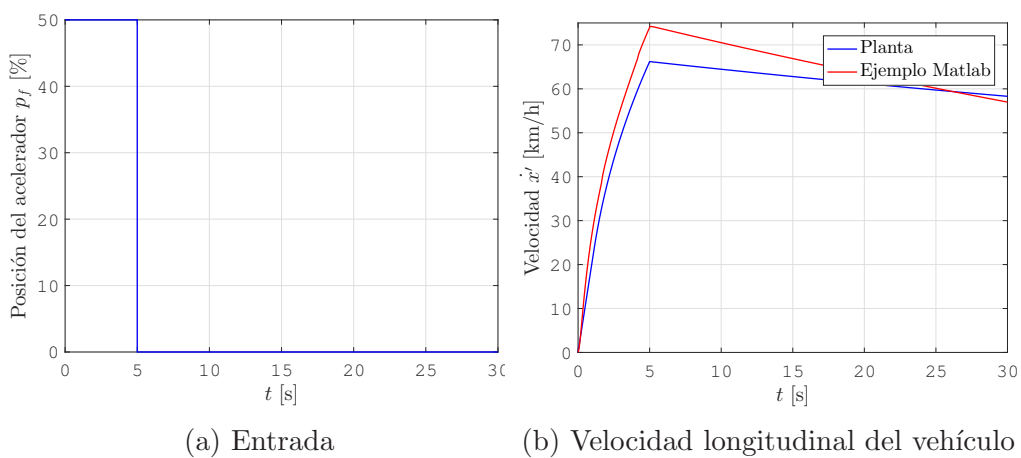


Figura 2-7: Resultados de simulación para el experimento de movimiento por inercia

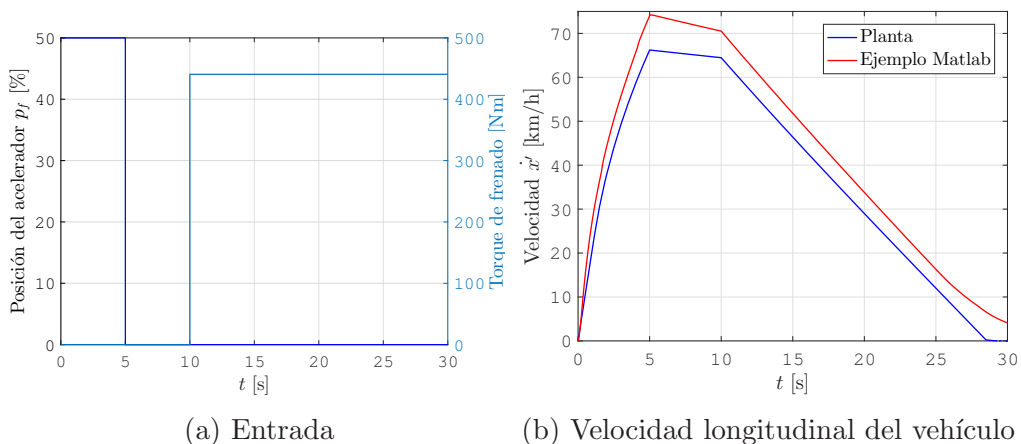


Figura 2-8: Resultados de simulación para el experimento de frenado

3 Generación de trayectorias de cambio de carril

En el capítulo 2 se presentó un modelo dinámico no lineal de vehículo del tipo “Single Track Model” (STM). Los modelos STM asumen que los ejes delanteros y traseros del vehículo se pueden representar por medio de una rueda, razón por la cual también se les conoce como “Modelo de bicicleta”. El modelo desarrollado permitió describir el comportamiento del vehículo bajo la acción de el ángulo de la rueda delantera (ángulo de viraje), la posición del acelerador y el torque de frenado. Este modelo se está descrito por las siguientes ecuaciones:

$$\dot{x} = f(x, u) \tag{3-1}$$

$$y = g(x, u) \tag{3-2}$$

con el vector de estados:

$$x = [x', y', \psi, \dot{x}', \dot{y}', \dot{\psi}, X_W, Y_W]^T \tag{3-3}$$

Siendo \dot{x}' la velocidad longitudinal del vehículo, y' su posición lateral respecto de su centro instantáneo de rotación, ψ su orientación y X_W y Y_w su posición en un sistema de referencia global. Recuérdese que x' y y' definen la posición del vehículo en el sistema de coordenadas local.

Por otra parte, el vector de entradas u es:

$$u = [\delta, p_f, M_B] \tag{3-4}$$

donde δ es la orientación de la rueda delantera del vehículo respecto de su eje, p_f es la posición del acelerador definida como un porcentaje y M_B es el torque de frenado. De manera que δ describe el comportamiento de dirección del vehículo, mientras que el par p_f y M_B describen su aceleración longitudinal.

El modelo STM no lineal en espacio de estados se muestra en la ecuación 3-5.

$$\underbrace{\begin{bmatrix} \dot{x}' \\ \dot{y}' \\ \dot{\psi} \\ \ddot{x}' \\ \ddot{y}' \\ \ddot{\psi} \\ \dot{X}_W \\ \dot{Y}_W \end{bmatrix}}_{\dot{\mathbf{x}}} = \underbrace{\begin{bmatrix} \dot{x}' \\ \dot{y}' \\ \dot{\psi} \\ -\frac{2\cos(\psi+\delta)x'}{3rm|x'|}M_B + \left(\frac{2\pi r i_d i_G P_M}{100x'} p_f - \frac{x'}{3|x'|}M_B\right) \frac{\cos\psi}{rm} + \frac{1}{2}c_w\rho_L A x' \sqrt{\dot{x}'^2 + \dot{y}'^2} \\ -\frac{2c_{\alpha,v}+2c_{\alpha,h}}{mx'}\dot{y}' - \left(\dot{x}' + \frac{2c_{\alpha,v}l_v - 2c_{\alpha,h}l_h}{mx'}\right)\dot{\psi} + \frac{2c_{\alpha,v}}{m}\delta \\ -\frac{2l_v c_{\alpha,v} - 2l_h c_{\alpha,h}}{\theta_{zz}x'}\dot{y}' - \frac{2l_v^2 c_{\alpha,v} + 2l_h^2 c_{\alpha,h}}{\theta_{zz}x'}\dot{\psi} + \frac{2l_v c_{\alpha,v}}{\theta_{zz}}\delta \\ \dot{x}' \cos(\psi) - \dot{y}' \sin(\psi) \\ \dot{x}' \sin(\psi) + \dot{y}' \cos(\psi) \end{bmatrix}}_{\mathbf{f}(\mathbf{x},\mathbf{u})} \quad (3-5)$$

Además, se supone que es posible medir directamente los estados Y_W y \dot{x}' , es decir:

$$y = \begin{bmatrix} Y_W \\ \dot{x}' \end{bmatrix} \quad (3-6)$$

Así, es posible asignar valores de referencia adecuados para generar las trayectorias deseadas. Específicamente, se puede tomar la distancia entre los centros de dos carriles como 3.3m para el valor de referencia de Y_W y para \dot{x}' , se tomará la velocidad a la cual se mueven los vehículos en el carril de destino o la máxima velocidad permitida en el mismo. Esta velocidad se denominará como \dot{x}'_{dest} . De esta manera, se tiene:

$$y_{ref} = \begin{bmatrix} 3.3 \\ \dot{x}'_{dest} \end{bmatrix} \quad (3-7)$$

En este capítulo, se plantea un problema de optimización basada en el modelo STM no lineal descrito por la ecuación 3-5, con el fin de obtener diferentes trayectorias de cambio de carril. Luego, se incorporará la presencia de otros vehículos en el carril de destino incluyendo una restricción adicional en el problema de optimización.

3.1. Problema de optimización

El problema de optimización con el cual se generarán las trayectorias de cambio de carril busca dos objetivos principales: alcanzar el carril de destino en el menor tiempo posible y regular las entradas necesarias para lograrlo, buscando preservar la estabilidad del vehículo. Esta optimización utiliza el modelo STM no lineal como modelo de predicción, discretizándolo con un período de muestreo T_s constante y con un horizonte de predicción N determinado, y se define como se indica en la ecuación 3-8.

$$\min_{u(1), \dots, u(N)} \sum_{k=1}^N \|y_{ref} - y(k)\|_Q^2 + \|u(k)\|_R^2 \quad (3-8)$$

Sujeto a:

$$x(k+1) = f(x(k), u(k)) \quad (3-9)$$

$$y(k) = g(x(k), u(k)) \quad (3-10)$$

$$u_{min} \leq u(k) \leq u_{max} \quad (3-11)$$

$$\Delta u_{min} \leq \Delta u(k) \leq \Delta u_{max} \quad (3-12)$$

$$\Delta x_{min} \leq \Delta x(k) \leq \Delta x_{max} \quad (3-13)$$

En la función objetivo 3-8, N es el horizonte de predicción dado en número de muestras. Esta función objetivo tiene dos términos: con el primero se busca minimizar el error entre los valores de referencia dados por 3-7 y la trayectoria del vehículo, el segundo término regulariza las entradas del modelo, las cuales se especifican en la ecuación 3-4. Esto se logra utilizando las formas cuadráticas dadas por las normas Q y R , de forma que:

$$\|y_{ref} - y(k+j)\|_Q^2 = (y_{ref} - y(k+j))^T Q (y_{ref} - y(k+j)) \quad (3-14)$$

$$\|u(k+j)\|_R^2 = u^T R u \quad (3-15)$$

Así, por medio de las matrices Q y R se asignan pesos relativos entre las salidas y las entradas para buscar que estas últimas sean suaves (de mínima energía) y para determinar el grado de importancia para alcanzar los valores de referencia. Estas matrices se conocen como matrices de sintonía en teoría de control.

Las ecuaciones de la 3-9 a la 3-12 son las restricciones del problema de optimización. Las restricciones de igualdad 3-9 y 3-10 indican que la solución dada por el método de optimización debe cumplir con el modelo dinámico STM no lineal. Las restricciones de desigualdad 3-11 y 3-12 indican los límites operacionales del vehículo, en este caso, los valores mínimos y máximos para el ángulo de viraje, la posición del acelerador y el torque de frenado y sus correspondientes tasas de cambio mínimas y máximas. Finalmente, la restricción de desigualdad 3-13 se incorporó para considerar las aceleraciones confortables. Con esta restricción es posible caracterizar diferentes modos de conducción, por ejemplo los modos deportivo y *drive*, donde los conductores experimentan aceleraciones mayores o menores, respectivamente. Estas condiciones también se pueden relacionar con el tipo de pasajero (agresivo y conservador, o de acuerdo a su edad) para aplicaciones de modelado de cambios de carril.

Resultados de simulación

El problema de optimización descrito en la ecuación 3-8 fue implementado en Matlab[®] y Simulink[®] teniendo en cuenta tres escenarios: dos para un vehículo liviano en los modos

de conducción deportivo y *drive* y un escenario para un vehículo pesado. Estos escenarios se diferencian por las restricciones de aceleraciones longitudinal y lateral máximas, como lo muestra la tabla **3-1**, donde los valores fueron tomados de [33] y [34], respectivamente. Los parámetros utilizados para los vehículos liviano y pesado se muestran en la tabla **3-2**. Vale la pena mencionar que para el vehículo liviano se consideraron los mismos parámetros utilizados en el capítulo 2 para las simulaciones del modelo STM no lineal en lazo abierto, mientras que para el vehículo pesado, se utilizaron los valores encontrados en [35], exceptuando la potencia del motor y el área transversal, las cuales se asumieron como 220 hp y 2.4 m, respectivamente y los parámetros $c_{\alpha,v}$, $c_{\alpha,h}$, i_D e i_G , donde se utilizaron los mismos que para el vehículo liviano.

Restricción	Modo deportivo	Modo <i>drive</i>	Camión
$\Delta x'_{min} [\text{m s}^{-2}]$	-4.5	-3	-3
$\Delta x'_{max} [\text{m s}^{-2}]$	2.6	1.5	1.5
$\Delta y'_{min} [\text{m s}^{-2}]$	-3.5	-2	-2
$\Delta y'_{max} [\text{m s}^{-2}]$	3.5	2	2

Tabla 3-1: Valores para las restricciones de aceleración en los modos de conducción deportivo y *drive* para un vehículo liviano y para un vehículo pesado, dados en m s^{-1}

	Liviano	Pesado	Unidades
m	1573	4255	kg
θ_{zz}	2873	34833	kg m^{-2}
l_v	1.10	2.5	m
l_h	1.58	1.77	m
$c_{\alpha,v}$	80000	80000	N
$c_{\alpha,h}$	80000	80000	N
c_w	0.4	0.4	-
ρ_L	1.29	1.29	kg m^{-3}
A	1.8	2.4	m^2
r	0.3	0.4	m
P_M	119312	164054	W
i_D	3.42	3.42	-
i_G	0.829	0.829	-

Tabla 3-2: Parámetros para la generación de trayectorias de cambio de carril para un vehículo liviano (tipo sedan) y un vehículo pesado

Para estos casos no se considera aún la presencia de vehículos en el carril de destino. Además, se realizaron simulaciones variando la velocidad inicial del vehículo \dot{x}'_0 y la velocidad de referencia \dot{x}'_{dest} , teniendo en cuenta los siguientes valores:

$$\dot{x}'_0 \in \{20, 25, \dots, 55\} \text{km h}^{-1} \quad (3-16)$$

$$\dot{x}'_{dest} \in \{25, 30, \dots, 60\} \text{km h}^{-1} \quad (3-17)$$

También se asumirá que la diferencia entre la velocidad de referencia y la velocidad inicial del vehículo no excederá los 15km h^{-1} , con lo cual se buscan unas características que se asemejen al tráfico urbano, exceptuando escenarios de congestión. Esto es:

$$\dot{x}'_0 < \dot{x}'_{dest} \leq \dot{x}'_0 + 15 \text{km h}^{-1} \quad (3-18)$$

Así, se generaron 21 trayectorias en total, con condiciones iniciales y valores de referencia dados por:

$$x_0 = [0, 0, 0, \dot{x}'_0, 0, 0, 0, 0]^T \quad (3-19)$$

$$y_{ref} = [3, 3, \dot{x}'_{dest}]^T \quad (3-20)$$

El hecho de que la velocidad de referencia siempre es mayor que la velocidad inicial indica que se consideró un escenario donde el cambio de carril representa una ganancia en velocidad, lo cual se presenta frecuentemente tanto en tráfico urbano como en autopistas, en donde los vehículos se mueven más rápido por el carril de la izquierda.

La tabla **3-3** muestra los parámetros utilizados en la optimización. De acuerdo con el período de muestreo T_s , el horizonte de predicción equivale a 5 s. Se tomó este horizonte de predicción como la duración máxima que puede tener un cambio de carril, la cual está en concordancia con los estudios realizados por Toledo [36], teniendo en cuenta que, en este caso, no se modelaron fenómenos como el rechazo de brechas, lo cual aumentaría la duración del cambio de carril. Adicionalmente, el valor de $M_{B,max}$ fue tomado de [29] y los valores de δ_{min} , δ_{max} , $\Delta\delta_{min}$ y $\Delta\delta_{max}$ fueron tomados de [37].

Parámetro	Valor	Unidades
T_s	0.2	s
N	25	-
$\delta_{min}, \delta_{max}$	-0.1745, 0.1745	rad
pf_{min}, pf_{max}	0, 100	%
$M_{B,min}, M_{B,max}$	0, 3500	N m
$\Delta\delta_{min}, \Delta\delta_{max}$	-0.0524, 0.0524	rad

Tabla 3-3: Parámetros para la generación de trayectorias mediante optimización

En cuanto a la sintonización de las matrices Q y R , se pudo encontrar que los términos asociados con p_f , δ y $Y_{W,ref}$ son los más sensibles, debido principalmente a la estrecha relación entre las aceleraciones longitudinal y lateral, lo cual significa que es necesario lograr una regulación adecuada simultánea de estas dos entradas, ya que darle mucha libertad a una de ellas afecta a la otra. En específico, se pudieron encontrar unos valores para las matrices Q y R que aplican para todas las condiciones iniciales especificadas en la ecuación 3-30, los cuales se muestran en la ecuación 3-21. En otras palabras, con los valores de estas matrices se pudieron obtener las trayectorias de cambio de carril viables en todos los escenarios propuestos.

$$\begin{aligned} Q &= \text{diag}(0.15, 10) \\ R &= \text{diag}(0.001, 0.01, 0.01) \end{aligned} \quad (3-21)$$

Para comparar el desempeño de las trayectorias de cambio de carril obtenidas, se utilizó el error cuadrático medio entre cada trayectoria y el valor de referencia $Y_{W,ref}$, como lo muestra la ecuación 3-22.

$$MSE_{Y_W} = \frac{1}{n} \sum_{k=1}^n (Y_W(k) - Y_{W,ref}(k))^2 \quad (3-22)$$

La figura **3-1a** muestra los errores MSE_{Y_W} obtenidos para las simulaciones con vehículo liviano en modos de conducción deportivo y *drive* y el vehículo pesado. Se seleccionaron dos grupos de trayectorias con diferentes rangos de error MSE_{Y_W} , las cuales se muestran en la figura **3-2**. Se puede observar en la figura **3-2a** que el conjunto de trayectorias con menor error cuadrático medio llegan más rápido a la referencia, alrededor de los 1.5 s pero muestran un sobreimpulso, mientras que en la figura **3-2b** las trayectorias no poseen dicho sobreimpulso y tardan más en alcanzar la referencia, alrededor de los 2 s. En este sentido, volviendo a la figura **3-1a**, se pudo verificar que debido a las restricciones de aceleración máxima permitidas, el vehículo en modo deportivo llega más rápido al carril de destino, lo cual está relacionado con el menor MSE_{Y_W} promedio. Al incrementar las restricciones de aceleración y la relación peso-potencia del vehículo, es más probable que se tarde más en alcanzar el carril de destino, lo cual se puede observar comparando con el MSE_{Y_W} promedio del modo *drive* y el camión. Sin embargo, la desventaja de alcanzar más rápido la referencia es la presencia del sobreimpulso, el cual puede implicar hasta 2 s en el tiempo de estabilización. La figura **3-1b** muestra los máximos sobreimpulsos para las trayectorias obtenidas, se observa que éstos no exceden los 40 cm, lo cual no representa un riesgo para el pasajero.

La figura **3-3a** muestra el ángulo de viraje δ obtenido para el vehículo liviano en los modos de conducción deportivo y *drive* y el vehículo pesado. Se seleccionó una sola trayectoria para realizar esta comparación, en este caso aquella cuyas velocidades inicial y de referencia son 40 km h^{-1} y 50 km h^{-1} , respectivamente. En los tres casos la forma que tiene esta entrada es similar, describiendo la siguiente secuencia:

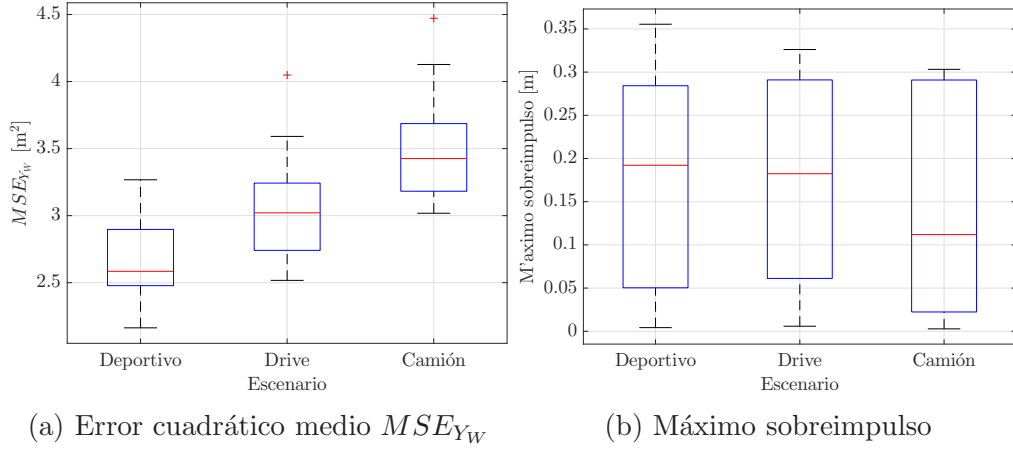


Figura 3-1: Error cuadrático medio y máximo sobreimpulso de las trayectorias obtenidas

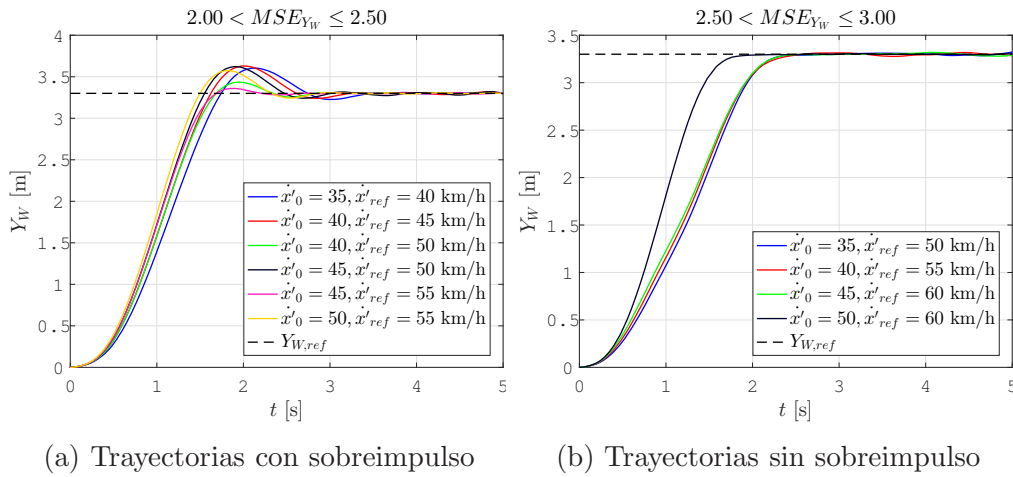


Figura 3-2: Trayectorias obtenidas en diferentes rangos de valores en el error cuadrático medio

- Se incrementa el ángulo de viraje cambiando la orientación del vehículo hacia el carril de destino
- Se decrementa el ángulo de viraje para que la orientación del vehículo coincida con la del carril de destino
- Se lleva el ángulo de viraje alrededor de cero para mantener el vehículo en el centro del carril de destino

La figura **3-3b** muestra las trayectorias obtenidas como resultado de esta secuencia de entradas. Se puede observar que el vehículo liviano alcanza más rápidamente la referencia en ambos modos de conducción, pero se presenta un pequeño sobreimpulso a diferencia de la trayectoria del vehículo pesado.




Figura 3-3: Entrada δ y posición del vehículo en Y_W para un vehículo liviano en modos de conducción deportivo y *drive* y un vehículo pesado

La figura 3-4 muestra la posición del acelerador y el torque de frenado y la velocidad obtenida. Nótese que, dado que en el modo de conducción *drive* para el vehículo liviano y en el vehículo pesado se utilizan los mismos límites de aceleración máxima (ver tabla 3-1), los cambios en la posición del acelerador requeridos son más pequeños, lo cual implica un tiempo mayor para alcanzar la referencia. En el caso del vehículo pesado toma aún más tiempo ya que su relación peso-potencia es mayor. También se puede apreciar que no se utiliza el freno, debido a que en todos los casos la velocidad de referencia es mayor que la velocidad inicial. La figura 3-5b, muestra las aceleraciones lateral y longitudinal obtenidas. Nótese la relación que hay entre el ángulo de viraje (figura 3-3a) y la aceleración lateral experimentada. También se puede observar que es más fácil mantener la velocidad de referencia debido a que la aceleración longitudinal decae a cero y se mantiene allí. Por otro lado, la aceleración lateral es mucho más sensible ante la entrada δ y es más difícil mantener el estado Y_W en el valor de referencia. Sin embargo, las desviaciones del centro del carril de destino son muy pequeñas, del orden de centímetros.

3.2. Inclusión de vehículos en el carril de destino

Para considerar la presencia de vehículos en el carril de destino, se propone una restricción no lineal adicional al problema de optimización 3-8. Supóngase un escenario como el que se muestra en la figura 3-6. Definiendo las posiciones de los vehículos en el instante k como:

$$\mathbf{r}_W^p(k) = [X_W^p(k), Y_W^p(k)]^T, \forall k = 1, \dots, N \quad (3-23)$$

$$\mathbf{r}_W^q(k) = [X_W^q(k), Y_W^q(k)]^T, \forall k = 1, \dots, N \quad (3-24)$$

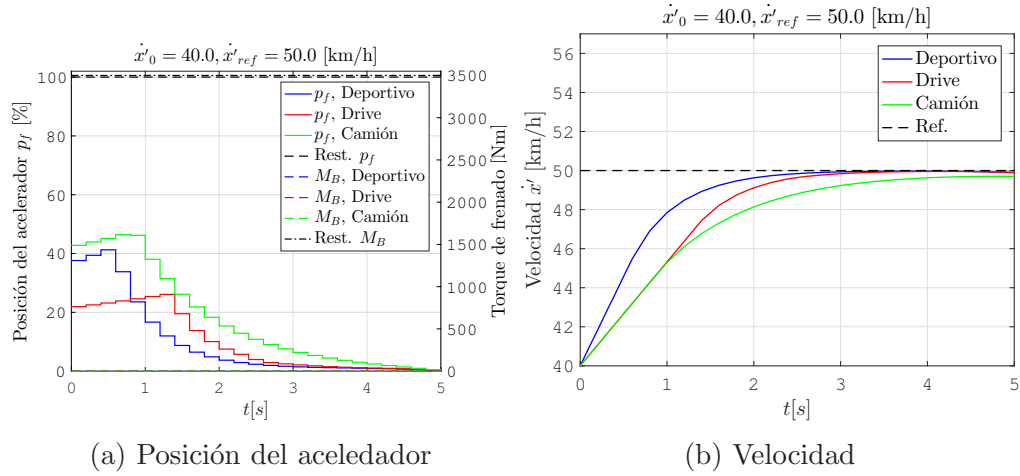


Figura 3-4: Posición del acelerador p_f y velocidad del vehículo x' para un vehículo liviano en modos de conducción deportivo y *drive* y un vehículo pesado

Donde se ha designado el vehículo que desea ejecutar el cambio de carril (vehículo sujeto) con el superíndice p y los vehículos en el carril de destino con el superíndice q , de manera que $p \neq q$. Entonces, la restricción adicional es:

$$d_{p,q}^2(k) \geq d_{safe}^2(Y_W), \forall k = 1, \dots, N \quad (3-25)$$

Siendo $d_{p,q}(k)$ la distancia entre el centro de masa del vehículo sujeto y el centro de masa del vehículo en el carril de destino q en el instante k , esto es:

$$d_{p,q}(k) = \|\mathbf{r}_W^p(k) - \mathbf{r}_W^q(k)\|, \forall k = 1, \dots, N \quad (3-26)$$

Es importante anotar que de acuerdo con la ecuación 3-25, es necesario tener un modelo de predicción de los vehículos en el carril de destino para obtener sus posiciones en el instante k . En este trabajo se simplificará este modelo asumiendo que los vehículos se mueven a una velocidad constante \dot{x}'_{dest} , de tal forma que:

$$\begin{aligned} \dot{X}_W^q &= \dot{x}'_{dest} \\ X_W^q(k) &= X_W^q(0) + k\dot{X}_W^q, \forall k = 1, \dots, N \end{aligned} \quad (3-27)$$

Por otro lado, la ecuación 3-25 indica que el vehículo sujeto debe respetar una distancia de seguridad $d_{safe}(Y_W)$ con los vehículos en el carril de destino. Esta distancia es función de la posición del vehículo en Y_W , ya que cuando éste se encuentra en el carril de origen, la distancia de seguridad está relacionada con el ancho de los vehículos, mientras que cuando se encuentra en el carril de destino, la distancia está relacionada con el largo de los vehículos,

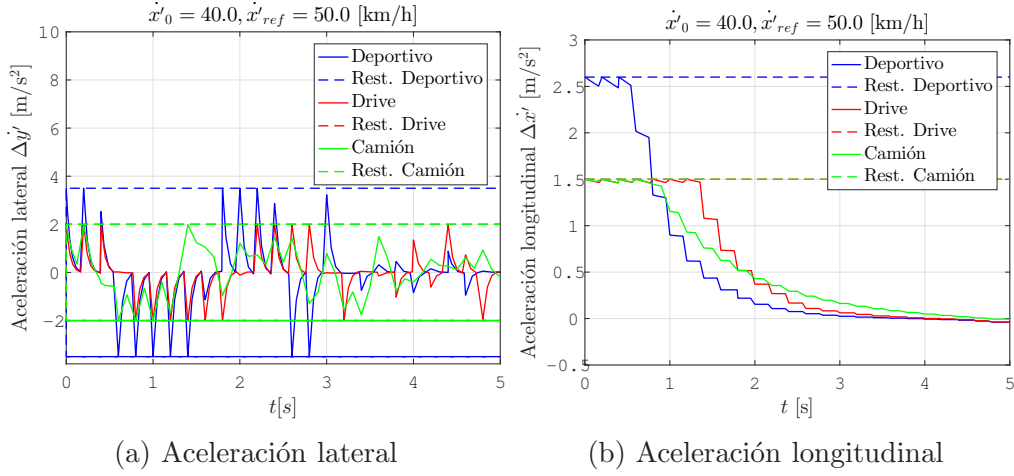


Figura 3-5: Aceleraciones laterales y longitudinales para un vehículo liviano en modos de conducción deportivo y *drive* y un vehículo pesado




Figura 3-6: Notación para las posiciones de los vehículos en un escenario de cambio de carril considerando vehículos en el carril de destino

como se muestra en la figura 3-7, donde w_l es el ancho del carril, w_V es el ancho de los vehículos y L_{dest} es el largo de los vehículos en el carril de destino, asumiendo que todos son idénticos. Así, la distancia d_{safe} se puede especificar mediante la ecuación 3-28.

$$d_{safe}(Y_W) = \left(\frac{d_{safe,L} - d_{safe,w}}{2} \right) \left[\tanh \left(6 \left(Y_W - \frac{w_l}{2} \right) \right) + 1 \right] + d_{safe,w} \quad (3-28)$$

donde:

$$\begin{aligned} d_{safe,L} &= \frac{L}{2} + \frac{L_{dest}}{2} + h_L \\ d_{safe,w} &= w_V + h_w \end{aligned} \quad (3-29)$$




Figura 3-7: Restricción de distancia segura $d_{safe}(Y_W)$ para cambio de carril con vehículos en el carril de destino

siendo L la longitud del vehículo sujeto, h_w el espaciamiento lateral entre vehículos y h_L el espaciamiento longitudinal entre vehículos. En este caso se asumió que el ancho del vehículo sujeto y el de los vehículos en el carril de destino es el mismo.

Resultados de simulación

Al igual que en la sección 3.1, el problema de optimización 3-8 fue implementado en Matlab[®] y Simulink[®] para los escenarios de vehículo liviano con modos de conducción deportivo y *drive* y para el vehículo pesado, incluyendo vehículos en el carril de destino con la restricción 3-25. En este caso, se consideraron solamente dos vehículos en el carril de destino, como lo muestra la figura 3-8. Estos vehículos se denominarán, de izquierda a derecha como vehículo retrasado (del inglés *lag vehicle*) y vehículo líder. Con estas condiciones, se buscó obtener tres situaciones representativas: vehículo sujeto adelantando al vehículo líder, vehículo sujeto adelantando al vehículo retrasado y vehículo sujeto ubicándose detrás del vehículo retrasado.




Figura 3-8: Notación para las condiciones iniciales de cambio de carril incluyendo dos vehículos en el carril de destino

Las simulaciones fueron realizadas variando las posiciones iniciales del vehículo sujeto, $X_W^1(0)$, y del vehículo líder $X_W^2(0)$, de la siguiente forma:

$$X_W^1(0) \in \{0, 5, 10, \dots, 40\}m \quad (3-30)$$

$$X_W^2(0) \in \{10, 20, 30\}m \quad (3-31)$$

Con la condición:

$$0 \leq X_W^1(0) \leq X_W^2(0) + 10m \quad (3-32)$$

Parámetro	Valor	Unidades
w_l	3.3	m
L , vehículo liviano	5	m
L , vehículo pesado	7	m
L_{dest}	5	m
h_l	2	m
h_w	1	m

Tabla 3-4: Parámetros requeridos para la restricción de distancia segura con los vehículos en el carril de destino

Tipo de vehículo	Trayectorias viables
Vehículo liviano en modo deportivo	102
Vehículo liviano en modo <i>drive</i>	83
Vehículo pesado	47

Tabla 3-5: Número de trayectorias viables obtenidas para las simulaciones incluyendo vehículos en el carril de destino

En cuanto a las velocidades iniciales, se siguieron utilizando las especificadas por la ecuación 3-30. Las condiciones iniciales para el vehículo sujeto y el retrasado son:

$$x_0 = [0, 0, 0, \dot{x}'_0, 0, 0, X_W^1(0), 0]^T \quad (3-33)$$

$$X_W^0(0) = 0$$

Los vehículos en el carril de destino se mueven a lo largo de la dirección X_W , por lo tanto:

$$Y_W^0(k) = Y_W^2(k) = 3.3 \text{ m}, \forall k = 1, \dots, N \quad (3-34)$$

Los parámetros adicionales para la restricción 3-26 se muestran en la tabla 3-4.

Se obtuvieron un total de 378 trayectorias para cada tipo de vehículo simulado: liviano en modos deportivo y *drive* y pesado. Estas trayectorias se evaluaron para descartar aquellos

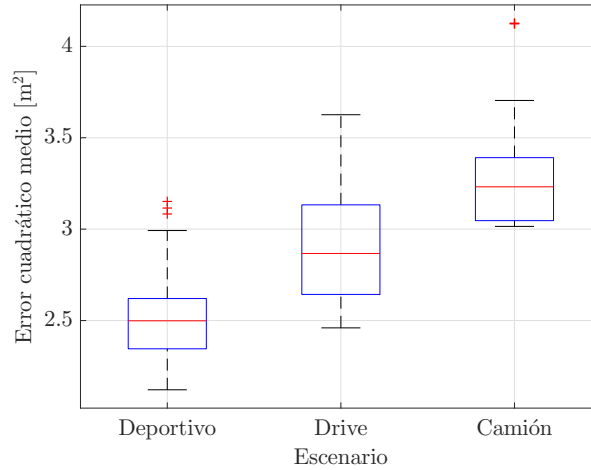


Figura 3-9: Error cuadrático medio de las trayectorias obtenidas con vehículos en el carril de destino

cambios de carril que no pudieron ser completados con éxito, obteniéndose el número de trayectorias viables mostrado en la tabla **3-5**.




Figura 3-10: Histograma de posiciones iniciales del vehículo sujeto $X_W^1(0)$ y el vehículo líder $X_W^2(0)$ que hacen viable la trayectoria de cambio de carril

La figura **3-9** muestra el error cuadrático medio de las trayectorias obtenidas, el cual se comporta de manera similar al obtenido con las trayectorias sin vehículos en el carril de destino (figura **3-9**). Se evaluaron también las condiciones iniciales que hacen el problema de optimización inviable. La figura **3-10** muestra el histograma de las parejas de posiciones iniciales del vehículo sujeto y el vehículo líder que resultaron en un cambio de carril exitoso. Se puede observar que la única combinación viable con la posición inicial del vehículo líder

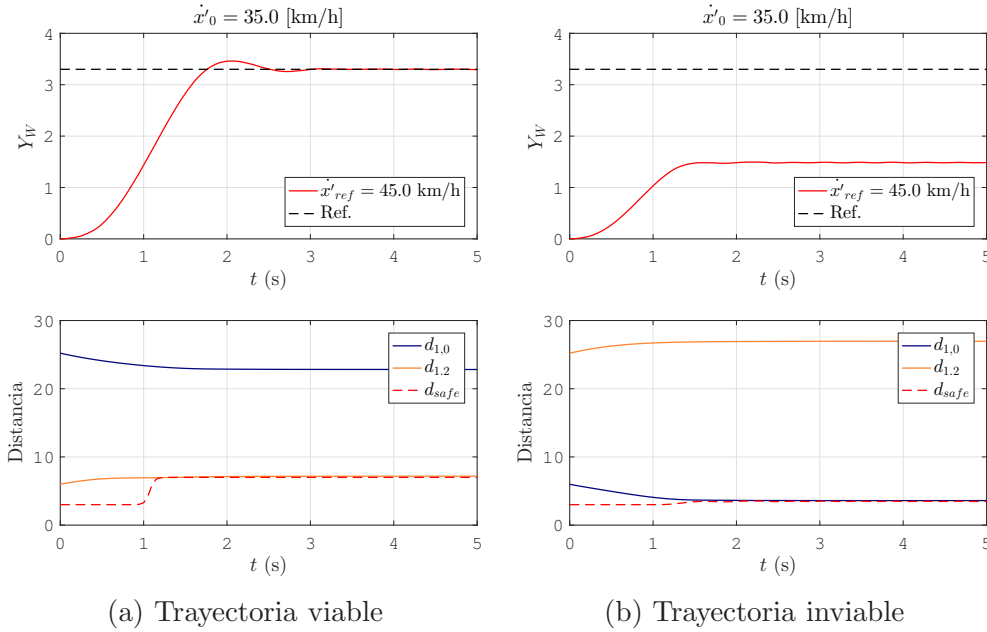


Figura 3-11: Comparación entre una trayectoria viable ($X_W^1(0) = 25$ m, $X_W^2(0) = 30$ m) y una inviable ($(X_W^1(0) = 5$ m, $X_W^2(0) = 30$ m)) para el vehículo liviano en modo deportivo

en $X_W^2(0) = 10$ m es cuando la posición inicial del vehículo sujeto es $X_W^1(0) = 20$ m, es decir cuando se ubica inicialmente delante del líder y lo adelanta, ya que la distancia de 10 m entre centros de masa entre este último y el vehículo retrasado representa una brecha muy pequeña. La distancia entre centros de masa debería ser, como mínimo, de $2d_{safe,L}$, que para el vehículo liviano sería de 14 m y para el vehículo pesado de 16 m. Otra observación importante es que el vehículo sujeto debe estar ubicado inicialmente por lo menos 10 m delante del vehículo retrasado o del vehículo líder para que la trayectoria sea viable. La figura 3-11 muestra una comparación entre una trayectoria viable y una inviable para el caso del vehículo liviano en modo deportivo. En este caso se observa que para la trayectoria no viable, el vehículo se ubica 5 m delante del vehículo retrasado, la maniobra no se puede completar aunque se respete la restricción de distancia segura y el vehículo sujeto permanece entre los dos carriles. Si bien se esperaban escenarios donde el vehículo sujeto disminuyera su velocidad hasta encontrar una la posición de los vehículos en el carril de destino que permitiera la maniobra, esto haría que no se alcance la velocidad de referencia o el mismo carril de destino dentro del horizonte de predicción propuesto.

Otro aspecto importante en la generación de trayectorias mediante optimización es que el tiempo promedio para generar una trayectoria es de 9 min, teniendo en cuenta que las simulaciones se hicieron en un computador con un procesador Intel®Core™ i7 y 8 Gb de memoria RAM. Este tiempo de cálculo es mucho mayor que los 5 s de horizonte de predicción y sería aún mayor en una implementación en un vehículo real, ya que los computadores a

bordo de vehículos poseen procesadores de doble núcleo en el mejor de los casos. Por esta razón, en los capítulos 4 y 5 se propone un sistema de aprendizaje de trayectorias de cambio de carril con un controlador LQR para corrección de errores, con el fin de reducir los tiempos de cálculo de las trayectorias.

4 Aprendizaje de trayectorias de cambio de carril utilizando redes neuronales

En el capítulo anterior se presentó una estrategia para obtener trayectorias de cambio de carril mediante un problema de optimización basado en el modelo STM no lineal presentado en el capítulo 2. A pesar de que se obtuvieron excelentes resultados para la generación de estas trayectorias, obtener una sola de ellas, dada la complejidad del problema de optimización no lineal, se puede tardar bastante teniendo en cuenta que existen infinitas combinaciones de condiciones iniciales. En este capítulo se presentará un sistema de aprendizaje supervisado de trayectorias de cambio de carril utilizando dos estrategias: una mediante una regresión lineal y otra utilizando una red neuronal prealimentada con una capa de entrada y una capa oculta. Las salidas de la red neuronal serán las acciones necesarias para llevar a cabo el cambio de carril por medio del ángulo de viraje δ y la posición del acelerador p_f . No se tendrá en cuenta el torque de frenado M_B debido a que, como se mostró en el capítulo anterior, para los escenarios en los cuales el cambio de carril representa una ganancia de velocidad, el freno no se utiliza. El sistema de aprendizaje de trayectorias propuesto será entrenado con un conjunto de trayectorias obtenidas a partir del problema de optimización basada en el modelo STM no lineal presentado en el capítulo 3.

4.1. Redes Neuronales

Una red neuronal artificial (ANN) es un sistema inspirado en el cerebro humano. El cerebro humano es un sistema altamente complejo, compuesto por millones de neuronas que tienen la capacidad de organizarse con el fin de ejecutar tareas tales como reconocimiento de patrones, percepción y control de la capacidad motriz [38]. Además, puede interactuar con el entorno y aprender a través de la experiencia, almacenando información que le permite tanto reaccionar de manera rápida ante una eventualidad, como planificar tareas complejas, predecir el comportamiento del ambiente que lo rodea y adaptarse ante los cambios del mismo. Estas características permiten que el cerebro posea áreas altamente especializadas para llevar a cabo cada tipo de tarea, gracias a la información y el reconocimiento del contexto en el que se encuentra.

La capacidad de una red neuronal para ejecutar una tarea específica se da por medio de la interconexión de los elementos básicos que la constituyen, llamados neuronas. El proceso mediante el cual se logra un buen desempeño en la ejecución de la tarea se denomina proceso

de aprendizaje, el cual para una red neuronal construida como un componente de software corresponde con un algoritmo. Cada neurona se conecta con otras a través de un canal que se denomina sinapsis, de manera que en el proceso de aprendizaje se le da mayor o menor prioridad a ciertas conexiones entre neuronas, lo que se conoce como el peso de la interconexión. Entre algunas de las ventajas de las redes neuronales se incluyen su habilidad para reproducir mapeos entrada-salida altamente no lineales de manera simple y rápida, el almacenamiento de información para ejecutar una tarea específica y la forma en que se adaptan ante cambios en su entorno.

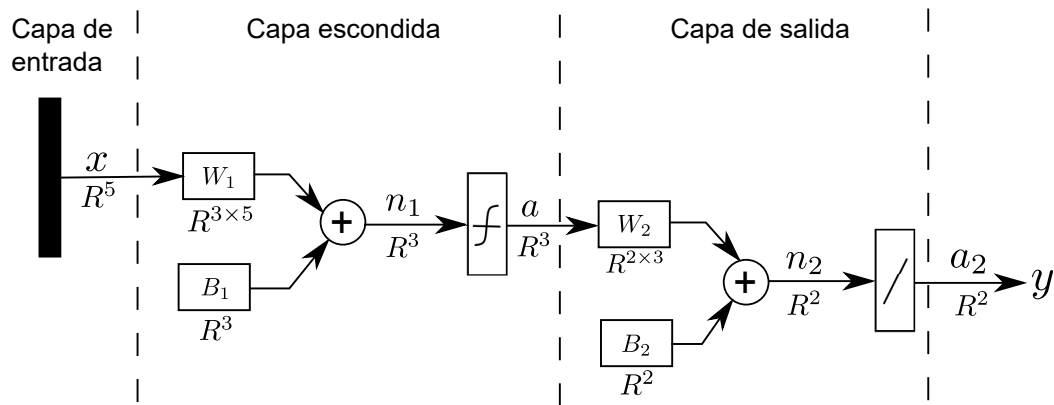


Figura 4-1: Red neuronal prealimentada con una capa escondida

Las redes neuronales pueden ser representadas como un grafo organizado en diferentes capas, donde por lo general se incluyen las siguientes:

- **Capa de entrada.** Esta capa representa la información del entorno obtenida por medio de sensores, donde los nodos representan cada una de las entradas a la red neuronal
- **Capas ocultas.** En estas capas, los nodos son las neuronas que reciben la información de la capa de entrada, aplicando diferentes pesos y adicionando un factor conocido como *bias*, con el cual se añade un efecto neto o un valor nominal a la señal de entrada [38]. Adicionalmente, la salida de esta capa es estimulada por medio de una función de activación, la cual idealmente corresponde con una función escalón, pero en la práctica se utilizan funciones sigmoideas como la función tangente hiperbólica, la cual facilita el proceso de aprendizaje utilizando algoritmos basados en el gradiente ya que es una función suave
- **Capa de salida.** Esta capa conecta la salida de la última capa escondida con la salida de la red neuronal, aplicando un conjunto de pesos. En esta capa también se puede producir la realimentación de la red neuronal, en donde la salida se vuelve a ingresar a una de las capas en la siguiente iteración del algoritmo de aprendizaje

Cuando la red neuronal está construida de tal forma que el flujo de información se da únicamente desde las entradas hacia las salidas, es decir sin realimentación, recibe el nombre de red neuronal prealimentada (*feedforward*).

La figura 4-1 muestra la representación gráfica de una red neuronal prealimentada con 5 nodos en la capa de entrada, una capa de 3 neuronas escondidas con una función de activación sigmooidal y dos salidas.

Matemáticamente, una red neuronal prealimentada de dos capas se puede describir mediante la ecuación:

$$y = W_2\Phi(W_1x + B_1) + B_2 \quad (4-1)$$

Donde x es la entrada, W_1 y B_1 son las matrices de pesos y de factor de *bias* de la capa escondida, W_2 y B_2 son las matrices de pesos y de factor de *bias* de la capa de salida y Φ su función de activación.

4.2. Diseño de la red neuronal

La red neuronal propuesta consiste en una red prealimentada de dos capas, con una capa de neuronas escondidas y una capa de salida (capa lineal), la cual se diseñará con la mayor cantidad de información entregada por el problema de optimización del generador de trayectorias de cambio de carril descrito en el capítulo 3. Se entrenará una red neuronal para cada modo de conducción y tipo de vehículo, asimilando las características de cada caso como la relación peso-potencia y las máximas aceleraciones permitidas. Por lo tanto, la información de entrada de la red neuronal consiste en el valor de la referencia en Y_W a lo largo del horizonte de predicción y los estados del vehículo sujeto y los vehículos del carril de destino en un instante de tiempo determinado, es decir:

$$x(k) = [Y_{W,ref}(1), \dots, Y_{W,ref}(N), x^0(k), x^1(k), x^2(k)]^T \in \mathbf{R}^{37} \quad (4-2)$$

donde se ha renombrado el vector de estados del vehículo sujeto como $x^1(k)$, para diferenciarlo de la entrada de la red neuronal y también se definieron los estados de los vehículos en el carril de destino como $x^0(k)$, para el vehículo retrasado y $x^2(k)$ para el vehículo líder, es decir:

$$\begin{aligned} x^1(k) &= [x'(k), y'(k), \psi(k), \dot{x}'(k), \dot{y}'(k), \dot{\psi}(k), X_W^1(k), Y_W^1(k)]^T \\ x^0(k) &= [X_W^0(k), \dot{X}_W^0(k)]^T \\ x^2(k) &= [X_W^2(k), \dot{X}_W^2(k)]^T \end{aligned} \quad (4-3)$$

Dado que el horizonte de predicción es $N = 25$ y el número de estados del vehículo sujeto y los vehículos del carril de destino es 12, se tiene entonces que $x \in \mathbf{R}^{37}$. Además, la red neuronal

se entrenará de manera estática, es decir, para cada entrada de la forma especificada por la ecuación 4-2, se tiene la salida $y = u(k) \in \mathbf{R}^{ny}$, siendo ny el número de salidas consideradas en la red neuronal, que pueden ser para el caso del cambio de carril δ , p_f o ambos. Por lo tanto, para el aprendizaje de una trayectoria completa, se necesita un conjunto de datos de tamaño N , el cual se obtiene mediante el problema de optimización basado en el modelo STM no lineal presentado en el capítulo 3. La figura 4-2 muestra el diseño de la red neuronal prealimentada.

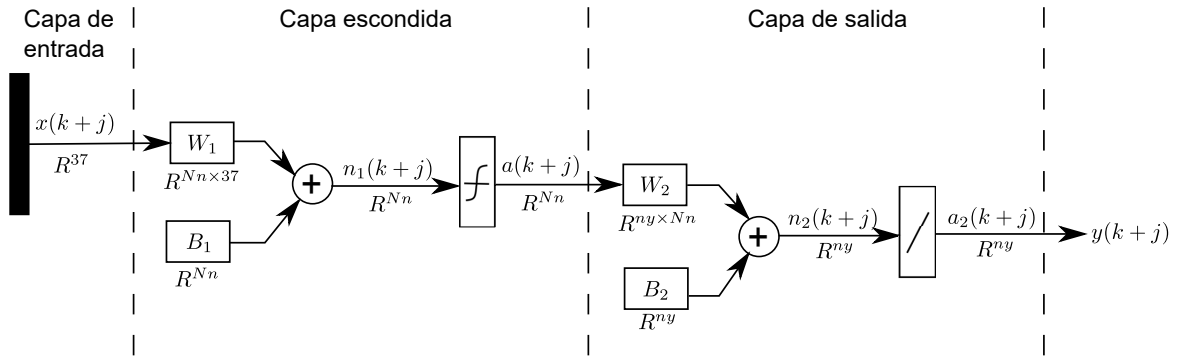


Figura 4-2: Diseño de la red neuronal prealimentada para el aprendizaje de trayectorias de cambio de carril

4.3. Aprendizaje mediante regresión lineal

El aprendizaje mediante regresión lineal es uno de métodos más sencillos, donde la principal hipótesis es que las salidas son una función lineal de las entradas, como lo muestra la ecuación 4-4.

$$y = X\theta \quad (4-4)$$

En donde las filas de la matriz X , corresponden con cada uno de los elementos del conjunto de trayectorias. Si se denotan estas trayectorias utilizando un subíndice desde 1 hasta m , siendo este último el número total de trayectorias, la matriz X se puede describir como se muestra en la ecuación 4-5.

$$X = \begin{bmatrix} x_1(k) & 1 \\ x_2(k) & 1 \\ \vdots & \vdots \\ x_m(k) & 1 \end{bmatrix} \quad \forall k = 1, \dots, N \quad (4-5)$$

En este caso, $X \in \mathbf{R}^{m \times (nx+ny)}$, con m el número de datos de entrada y $\theta \in \mathbf{R}^{(nx+ny) \times ny}$ son los pesos. Esta red neuronal se reduce a un problema de mínimos cuadrados, donde se busca minimizar el error entre la salida de la red neuronal y y el objetivo d .

La solución de 4-5 es:

$$\theta = X^\dagger y = (X^T X)^{-1} X^T y \quad (4-6)$$

donde X^\dagger es la matriz pseudo-inversa de Moore-Penrose, cuya definición es:

$$X^\dagger = (X^T X)^{-1} X^T \quad (4-7)$$

Es importante mencionar que la matriz $(X^T X)^{-1}$ debe estar bien condicionada, de lo contrario, una herramienta poderosa para realizar aproximaciones de bajo rango es la descomposición en valores singulares o SVD, la cual consiste en representar la matriz X como:

$$X = U \Sigma V^T \quad (4-8)$$

donde $U \in \mathbf{R}^{m \times r}$ es una base ortonormal del rango de X , siendo r el rango de la matriz, $V \in \mathbf{R}^{(nx+ny) \times r}$ es una base ortonormal del subespacio nulo de X y $\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r)$ son sus valores singulares. La aproximación de bajo rango consiste en eliminar los valores singulares menos significativos de la matriz Σ , de la siguiente forma:

$$X \approx [u_1 \ u_2 \ \dots \ u_p] \begin{bmatrix} \sigma_1 & & & \\ & \sigma_2 & & \\ & & \ddots & \\ & & & \sigma_p \end{bmatrix} \begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_p \end{bmatrix} \quad (4-9)$$

de manera más compacta:

$$X \approx U_1 \Sigma_1 V_1^T \quad (4-10)$$

Con $p < r$. Finalmente, la matriz pseudo-inversa \tilde{x}^\dagger por medio de la descomposición SVD es:

$$X^\dagger \approx V_1 \Sigma_1^{-1} U_1^T \quad (4-11)$$

Para el aprendizaje de las trayectorias de cambio de carril, el número de datos es el valor del horizonte de predicción utilizado para generarlas, multiplicado por el número de trayectorias.

Por ejemplo, para el caso del vehículo deportivo se obtuvo $m = 2500$, que es el horizonte de predicción utilizado $N = 25$ por el número de trayectorias seleccionadas, o sea 100. Para este ejemplo, el análisis de la condición de la matriz X se realizó hallando la descomposición en valores singulares en Matlab[®], utilizando la siguiente lista de código:

```
% Hallar la descomposición en valores singulares
[U,S,V]=svd(X,0);
singular_values = diag(S);

% Encontrar los valores singulares más significativos
p = length(find(singular_values>1e-6))

% Realizar la aproximación de bajo rango
U1 = U(:, 1:p);
V1 = V(:, 1:p);
S1 = S(1:p, 1:p);

% Hallar la matriz pseudo-inversa
X_inv_svd = V1*inv(S1)*U1';
```

En este caso, el valor p resultó en:

$p =$

12

Este resultado se explica de acuerdo con la ecuación 4-2, el primer elemento $Y_{W,ref}(k)$ no aporta ninguna información, ya que en todos los casos este valor es el mismo. Finalmente, los valores objetivo de la red neuronal son:

$$u_d = [u_1(1), u_1(2), \dots, u_1(N), u_2(1), \dots, u_{100}(N)]^T \quad (4-12)$$

4.4. Aprendizaje mediante una red neuronal prealimentada

Como se indicó en la sección 4.1, una red neuronal prealimentada de dos capas se puede describir por medio de la ecuación 4-13, donde $x \in \mathbf{R}^{nx}$, $W_1 \in \mathbf{R}^{N_n \times nx}$ es la matriz de pesos de la capa escondida, siendo N_n su número de neuronas $B_1 \in \mathbf{R}^{N_n}$ es el factor de *bias* en la capa escondida, $W_2 \in \mathbf{R}^{n_y \times N_n}$ y $B_2 \in \mathbf{R}^{n_y}$ son la matriz de pesos y el factor de *bias* en la capa de salida, respectivamente. Finalmente, Φ es el vector de funciones de activación de las neuronas en la capa escondida, que corresponde con un mapeo no lineal de \mathbf{R}^{N_n} en \mathbf{R}^{N_n} .

$$y = W_2 \Phi(W_1 x + B_1) + B_2 \quad (4-13)$$

Para facilitar la convergencia del algoritmo de entrenamiento, se efectúa una normalización de la entrada x , de forma que la ecuación 4-14 se puede escribir como:

$$y = W_2\Phi(W_1N_1(x - \bar{x}) + B_1) + B_2 \quad (4-14)$$

Donde \bar{x} contiene la media de cada una de las entradas definidas en la ecuación 4-2 y N_1 es una matriz diagonal que contiene su rango.

La red neuronal se inicializará con los parámetros obtenidos por medio de la regresión lineal. Para esto, se condicionarán las matrices W_1 y B_1 para trabajar en la zona lineal de la función de activación sigmoideal, la cual se ubica en valores pequeños de su argumento. En otras palabras, se debe garantizar que $0.1 \leq W_1x + B_1 \leq 0.1$. Particularmente, utilizando una función tangente hiperbólica se tiene que en la zona lineal:

$$\tanh(W_1x + B_1) \approx W_1x + B_1 \quad (4-15)$$

Reemplazando 4-15 en 4-14, se obtiene:

$$y \approx W_2W_1x + W_2B_1 + B_2 \quad (4-16)$$

Comparando la ecuación 4-16 con la 4-6, se llega a:

$$\begin{aligned} W_2W_1 &= [\theta_1, \dots, \theta_{12}]^T \\ W_2B_1 + B_2 &= \theta_{13} \end{aligned} \quad (4-17)$$

La ecuación 4-17 indica que los pesos de una red neuronal se pueden inicializar a partir de la solución del problema mediante regresión lineal. En general, se puede comenzar generando W_1 con valores aleatorios suficientemente pequeños y obtener así W_2 , B_1 y B_2 . Sin embargo, se utilizará la matriz V de la descomposición en valores singulares de X , como se vio en la ecuación 4-8, ya que esta matriz tiene la propiedad de generar el subespacio del conjunto de llegada, con lo cual se puede mejorar la convergencia de la red neuronal.

La implementación de la red neuronal se hizo utilizando la *toolbox* de redes neuronales de Matlab[®], utilizando una función tangente hiperbólica como función de activación y el algoritmo de optimización de Levenberg-Marquardt para el entrenamiento. Finalmente, para el número de neuronas en la capa escondida se eligió como criterio utilizar el rango de la matriz X con aproximación de bajo rango (ecuación 4-10) utilizada en la red neuronal lineal, es decir $N_n = p = 12$.

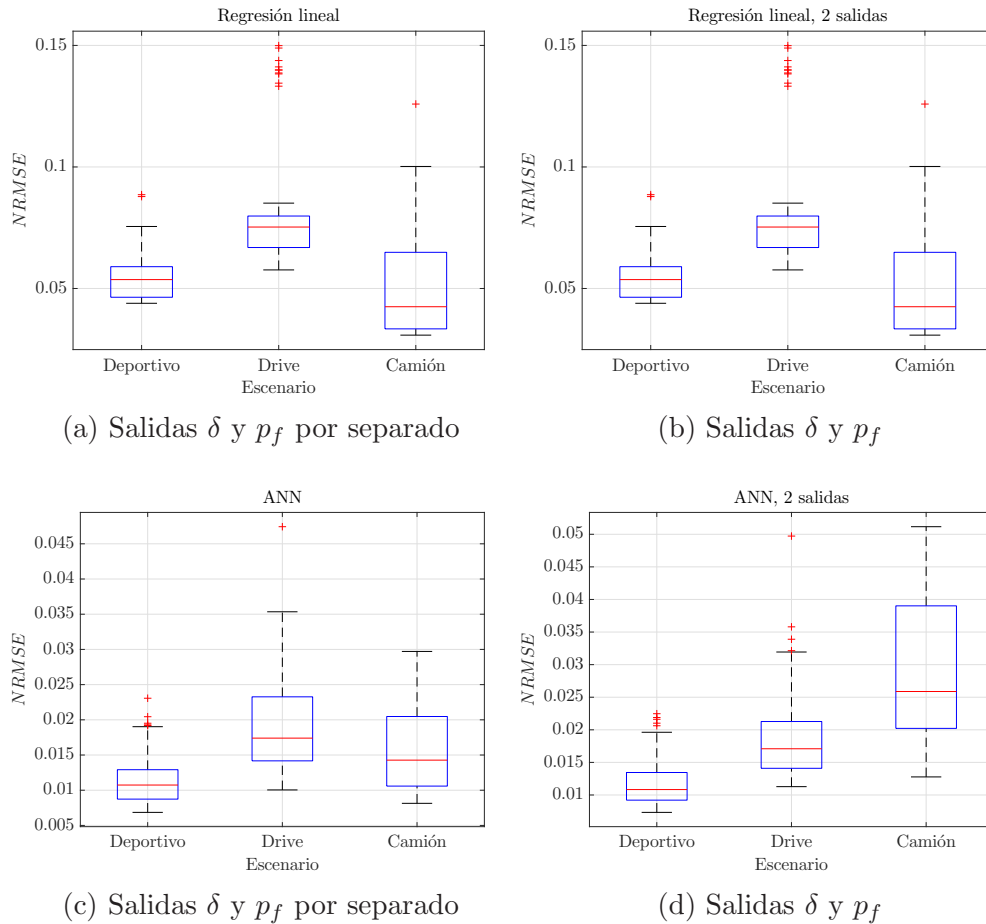


Figura 4-3: Error cuadrático medio para las cuatro estrategias de aprendizaje implementadas con los resultados para vehículo liviano en modos deportivo y *drive* y el camión

4.5. Resultados

Para evaluar la validez de los sistemas de aprendizaje de trayectorias de cambio de carril basados en regresión lineal y redes neuronales propuestos en las secciones 4.3 y 4.4, se implementaron tres versiones de cada uno: dos para cada salida δ y p_f y uno con ambas salidas, utilizando como conjunto de datos cien trayectorias seleccionadas para el caso del vehículo liviano en modo deportivo. Para el entrenamiento de la red neuronal, los datos fueron clasificados de la siguiente manera: 70 % para entrenamiento, 15 % para validación cruzada y 15 % para *testing*, lo que significa que este último 15 % son los datos desconocidos para la red neuronal, y con los cuales se evalúa su capacidad de generalización. La figura 4-3 muestra el error cuadrático medio normalizado (NRMSE) de los sistemas de aprendizaje para cada uno de los casos, el cual se define como se muestra en la ecuación . Se puede observar que el menor error se obtuvo con el entrenamiento de dos redes neuronales para las salidas δ y p_f . También, es importante mencionar que las salidas δ y p_f difieren en cuanto a la escala

de sus valores. δ está dada en radianes, con un valor máximo de 0.1745 rad (15°), mientras que p_f es la posición del acelerador dada en porcentaje con un valor máximo de 100%. Por esta razón, las redes neuronales fueron entrenadas con $p_f/100$ como salida y se utilizó el NRMSE, el cual permite tener en cuenta variables que no poseen las mismas unidades.

Los resultados obtenidos para el entrenamiento de dos redes neuronales para las salidas δ y p_f fueron evaluados en las trayectorias donde se presentaron el mayor y menor error cuadrático medio.

La figura 4-4 muestra la evaluación de una de las trayectorias del conjunto de datos. Se evidencian muy buenos resultados para las dos salidas, exceptuando el valor de p_f de la regresión lineal diseñada con δ y p_f .

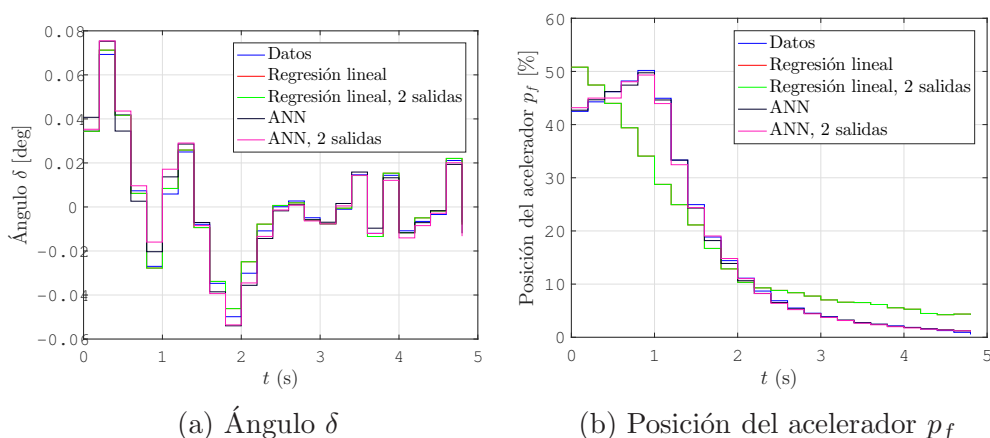


Figura 4-4: Comparación de las salidas para una trayectoria

Sin embargo, a pesar de que los errores de δ y p_f son pequeños de acuerdo con la figura 4-3c, al ingresar estos valores al modelo del vehículo, para obtener su trayectoria, se pueden alcanzar estados indeseables. Por ejemplo, el vehículo puede llegar al carril de destino con una orientación incorrecta, como lo muestra la figura 4-5b. Esta trayectoria corresponde con uno de los valores *outlier* de la figura 4-3c. Nótese que este ángulo δ es muy sensible a los errores, a diferencia de la velocidad en relación con la posición del acelerador p_f , como lo muestra la figura 4-5d. En el siguiente capítulo, se presenta un controlador LQR basado en un modelo lineal del vehículo para corregir los errores en la orientación del vehículo.

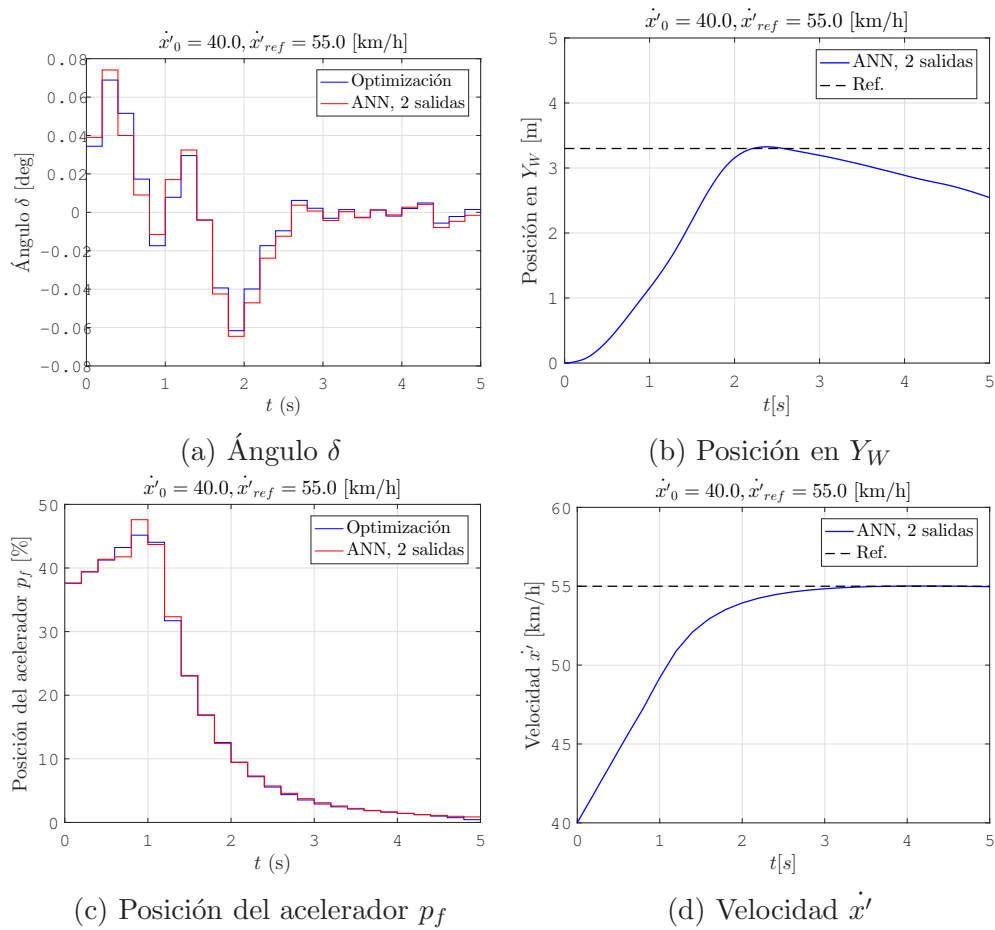


Figura 4-5: Trayectoria y velocidad del vehículo de acuerdo con las entradas producidas por la red neuronal

5 Control LQR para corrección de errores

En el capítulo 4, se presentó un sistema de aprendizaje supervisado de trayectorias de cambio de carril entrenado con un conjunto de trayectorias obtenidas por medio de un problema de optimización basado en modelo, presentado en el capítulo 3. Este sistema de aprendizaje se implementó con el fin de simplificar y mejorar los tiempos en la generación de estas trayectorias. Sin embargo, se comprobó que las acciones de control aprendidas poseen pequeños errores, los cuales no afectan considerablemente la velocidad del vehículo, pero sí la orientación con la que éste llega al carril de destino, de manera que no se logra el seguimiento de la referencia, es decir, la posición del centro del carril de destino. En este capítulo, se presenta un controlador *Linear Quadratic Regulator* (LQR) basado en un modelo lineal del vehículo para corregir estos errores y mantenerlo en la posición deseada. Un LQR es un controlador óptimo, en donde la ganancia K dada por la ley de control $u = -Kx$ se obtiene a partir de la solución del siguiente problema de optimización, para el caso discreto:

$$\min_{u(1), \dots, u(N-1)} x(N)^T P x(N) + \sum_{k=0}^{N-1} x(k)^T Q x(k) + u^T(k) R u \quad (5-1)$$

Sujeto a:

$$x(k+1) = Ax(k) + Bu(k) \quad (5-2)$$

$$y(k) = Cx(k) + Du(k) \quad (5-3)$$

Nótese que se trata de un problema de optimización muy similar al usado para el generador de trayectorias basado en modelo, con la diferencia de que en este caso, se tiene un modelo lineal del vehículo y no se cuenta con restricciones operativas de desigualdad, las cuales se asume que fueron asimiladas por el sistema de aprendizaje de trayectorias.

La solución del problema de optimización 5-1 se puede encontrar por medio de diferentes métodos, entre ellos están las ecuaciones de Hamilton-Jacobi y programación dinámica [39]. Los controladores LQR se pueden diseñar para llevar los estados a cero, es decir, con fines de regulación, o para el seguimiento de una referencia. En este caso, es posible implementar un controlador LQR teniendo en cuenta el error entre el estado Y_W obtenido al aplicar la acción de control δ obtenida por medio del sistema de aprendizaje de trayectorias, y el mismo estado obtenido mediante el generador de trayectorias basado en optimización, de manera

que este error se lleve a cero. El esquema del controlador LQR en conjunto con el sistema de aprendizaje de trayectorias se muestra en la figura 5-1.

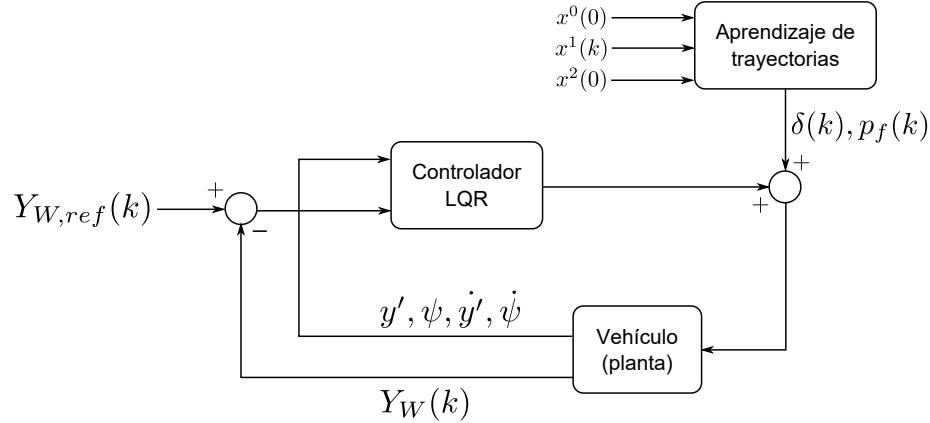


Figura 5-1: Controlador *Linear Quadratic Regulator* (LQR)

5.1. Linealización del modelo del vehículo

La linealización del modelo STM no lineal del vehículo, presentado en el capítulo 2, se realiza alrededor de una velocidad constante, obteniéndose un modelo muy similar al STM lineal descrito en la sección 2.1, excepto por la presencia del estado Y_W . En este caso, se toma una aproximación de Taylor de primer orden sobre la ecuación diferencial de este estado, teniendo en cuenta que la evaluación del gradiente se hace sobre un punto de la trayectoria con la cual se realiza la linealización. De esta manera, se obtiene un modelo lineal de la forma:

$$\dot{x} = Ax + Bu \quad (5-4)$$

Siendo el vector de estados $x = [y, \psi, \dot{y}, \dot{\psi}, Y_W]^T$ y las matrices A y B dadas por:

$$A = \begin{bmatrix} 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & -\frac{2c_{\alpha,v} + 2c_{\alpha,h}}{m\dot{x}'_{ss}} & -\dot{x}'_{ss} - \frac{2c_{\alpha,v}l_v - 2c_{\alpha,h}l_h}{m\dot{x}'_{ss}} & 0 \\ 0 & 0 & -\frac{2l_v c_{\alpha,v} - 2l_h c_{\alpha,h}}{\theta_{zz}\dot{x}'_{ss}} & -\frac{2l_v^2 c_{\alpha,v} + 2l_h^2 c_{\alpha,h}}{\theta_{zz}\dot{x}'_{ss}} & 0 \\ 0 & \dot{x}'_{ss}\cos(\psi_{ss}) - \dot{y}'_{ss}\sin(\psi_{ss}) & \cos(\psi_{ss}) & 0 & 0 \end{bmatrix} \quad (5-5)$$

$$B = \left[0, 0, \frac{2c_{\alpha,v}}{m}, \frac{2l_v c_{\alpha,v}}{\theta_{zz}}, 0 \right]^T$$

En este caso, se tomó una trayectoria que no presentara sobreimpulso y se tomó el primer punto de esta trayectoria. Adicionalmente, el modelo lineal se discretizó utilizando la misma tasa de muestreo que el generador de trayectorias basado en optimización, es decir 0.2 s.

5.2. Resultados

El controlador LQR descrito anteriormente fue implementado en Matlab[®] y Simulink[®], utilizando la *Control Systems Toolbox* para solucionar el problema de optimización de la ecuación 5-1 y obtener la ganancia K del LQR. Inicialmente, se retomó la trayectoria con la cual se evidenciaron los problemas de orientación del vehículo en el capítulo 4 (figura 4-5), obteniéndose los resultados que se observan en la figura 5-2. Recuérdese que esta trayectoria pertenece al vehículo liviano en modo deportivo.




Figura 5-2: Trayectoria del vehículo obtenida mediante con corrección utilizando un controlador LQR

Es importante notar que para la implementación del controlador LQR las entradas debieron ser interpoladas, ya que, aunque sin interpolar también se pudo corregir el error en la orientación, la discretización hace que se presenten altas aceleraciones laterales, las cuales no se encuentran dentro de las aceleraciones permitidas para el vehículo liviano en modo deportivo. Adicionalmente, la figura 5-2 muestra la trayectoria con la cual linealizó el modelo del vehículo, para el diseño del controlador LQR.

En cuanto al tiempo requerido para generar una trayectoria, se encontró que el promedio es de 1.2 s utilizando el sistema compuesto por la red neuronal y el controlador LQR. Este tiempo es mucho menor al requerido para la generación de trayectorias mediante el problema de optimización no lineal descrito en el capítulo 3, el cual es de 9 min. Por lo tanto, el esquema de la red neuronal más el controlador LQR es mucho más adecuado para una implementación de cambio de carril en un vehículo autónomo, teniendo en cuenta que la red neuronal ofrece

un desempeño similar al del problema de optimización ya que los resultados de este último fueron utilizados para el entrenamiento.

6 Conclusiones y recomendaciones

6.1. Conclusiones

En esta tesis se presentó un sistema de toma de decisiones basado en modelo para cambios de carril en vehículos autónomos, el cual se compone de distintos módulos los cuales fueron presentados en cada capítulo. En el capítulo 2 se propuso un modelo dinámico no lineal del vehículo con base en un modelo del tipo “Single Track Model” (STM). Este modelo permite caracterizar diferentes tipos de vehículos con parámetros como la masa del vehículo y la potencia del motor, con lo cual es posible no solamente caracterizar el vehículo en su comportamiento lateral, es decir al girar utilizando como entrada el ángulo de la rueda delantera, sino también en su comportamiento longitudinal, es decir en términos de la aceleración de acuerdo con la posición del acelerador y el torque de frenado. Este modelo fue analizado y validado mediante simulación comparando su dinámica longitudinal con un ejemplo existente de Matlab[®]. En el capítulo 3 se propuso un problema de optimización basado en el modelo STM no lineal para la generación de trayectorias de cambio de carril, el cual incluye restricciones operativas del vehículo, restricciones de aceleración máxima permitida para caracterizar diferentes modos de conducción en vehículos autónomos y diferentes tipos de conductores en aplicaciones de modelado de cambios de carril y restricciones para la consideración de vehículos en el carril de destino. El sistema de generación de trayectorias de cambio de carril fue implementado en simulación para obtener diferentes trayectorias considerando un vehículo liviano con dos modos de conducción: un modo deportivo, donde se toleran mayores aceleraciones, lo cual correspondería con un conductor propenso a ser más agresivo, y un modo *drive* donde se toleran aceleraciones más pequeñas, lo cual correspondería a un conductor más conservador; y un vehículo pesado. Además, se variaron las condiciones iniciales del vehículo que ejecuta la maniobra de cambio de carril y los vehículos en el carril de destino para considerar diferentes brechas y velocidades. Las trayectorias obtenidas para estos escenarios fueron analizadas, obteniendo resultados satisfactorios al comparar el vehículo liviano en los dos modos de conducción y el vehículo pesado, e identificando el conjunto de condiciones que permiten un cambio de carril exitoso. En el capítulo 4, se propuso un sistema de aprendizaje de trayectorias de cambio de carril utilizando una red neuronal prealimentada de dos capas, la cual fue entrenada en un esquema supervisado con cien trayectorias obtenidas para el vehículo liviano en modo deportivo. La red neuronal fue diseñada de manera estática, de tal manera que mapea los estados del vehículo en un instante determinado con sus correspondientes entradas, en este caso el ángulo de la rueda delantera y la posición del

acelerador. Se implementaron en total cuatro esquemas de aprendizaje de trayectorias: dos utilizando regresión lineal y otros dos utilizando redes neuronales. El desempeño de estas redes neuronales fue evaluado y comparado con el método de aprendizaje con regresión lineal, resultando las redes neuronales las que presentaron mejor desempeño. Sin embargo, los errores de la red neuronal relacionados con el ángulo de la rueda delantera algunas veces conllevan a errores indeseados en la orientación del vehículo que hacen que éste no se mantenga en el carril de destino. Por esta razón, en el capítulo 5 se presentó un controlador *Linear Quadratic Regulator* (LQR), el cual utiliza un modelo lineal del vehículo. Con el sistema compuesto por la red neuronal y el controlador LQR, fue posible simplificar el sistema de toma de decisiones para reducir la dependencia de generar trayectorias con una optimización no lineal basada en modelo, la cual es muy costosa computacionalmente, de manera que resulta más adecuado para las implementaciones en tiempo real que requieren los vehículos autónomos.

6.2. Recomendaciones

Como trabajos futuros se sugieren la refinación del modelo STM no lineal para representar la planta incluyendo un análisis de estabilidad y su validación con datos reales. Por otro lado se propone el desarrollo de modelos simplificados de esta planta, preferiblemente convexos, para reducir el costo computacional del problema de optimización encargado de la generación de trayectorias. Finalmente, se sugiere el desarrollo de un controlador predictivo (MPC) para la ejecución de la maniobra por un vehículo autónomo, que considere perturbaciones e incluya las entradas producidas por la red neuronal.

Bibliografía

- [1] Organisation mondiale de la santé. *Global status report on road safety 2015*. World Health Organization, Geneva (Switzerland), 2015.
- [2] JM Anderson, K Nidhi, KD Stanley, and P Sorensen. *Autonomous vehicle technology: A guide for policymakers*. RAND, 2016.
- [3] Directorate General for Transport European Commission. *European Commission, Annual Accident Report 2016*. jun 2016.
- [4] Daniel A. Rodríguez, Manuel Santana, and Carlos Felipe Pardo. *La Motocicleta en América Latina: Caracterización de su Uso e Impactos en la Movilidad en Cinco Ciudades de la Región*. Despacio, Bogota, Colombia, 2015.
- [5] MINSALUD. Mortalidad y lesiones por accidentes de transporte en Colombia, 2013-2014, October 2015.
- [6] Ministerio de transporte. Plan Nacional de Seguridad Vial Colombia 2011-2021, 2015.
- [7] R Planzer. *La seguridad vial en la región de América Latina y el Caribe: Situación actual y desafíos*. Naciones Unidas, 2005.
- [8] Collaboration United Nations. Global plan for the Decade of Action for Road Safety 2011–2020. *Geneva: WHO*, 2011.
- [9] Ministerio de transporte. Resolución Número 3752 de 2015, 2015.
- [10] NHTSA. Federal Motor Vehicle Safety Standards: Electronic Stability Control Systems; Controls and Displays. Technical report, 2007.
- [11] NHTSA. Federal Motor Vehicle Safety Standards: Hydraulic and Electric Brake Systems - Passenger Cars. Technical report.
- [12] Brad Schofield. *Model-Based Vehicle Dynamics Control for Active Safety*. PhD thesis, Lund University, 2008.
- [13] Todd Litman. Autonomous Vehicle Implementation Predictions: Implications for Transport Planning. *Transportation Research Board Annual Meeting*, (2014):36–42, 2014.

-
- [14] David Banister. The sustainable mobility paradigm. *Transport Policy*, 15(2):73–80, 2008.
- [15] Matthias Gerdts, Simon Karrenberg, Bernhard Müller-Bessler, and Gregor Stock. Generating locally optimal trajectories for an automatically driven car. *Optimization and Engineering*, 10(4):439–463, 2009.
- [16] Cheng Chen, Yuqing He, Chunguang Bu, Jianda Han, and Xuebo Zhang. Quartic Bézier curve based trajectory generation for autonomous vehicles with curvature and velocity constraints. In *Proceedings - IEEE International Conference on Robotics and Automation*, pages 6108–6113, 2014.
- [17] J. M. Park, D. W. Kim, Y. S. Yoon, H. J. Kim, and K. S. Yi. Obstacle avoidance of autonomous vehicles based on model predictive control. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 223(12):1499–1516, 2009.
- [18] Ashwin Carvalho, Yiqi Gao, Stéphanie Lefèvre, and Francesco Borrelli. Stochastic predictive control of autonomous vehicles in uncertain environments. *Proc. 12th International Symposium on Advanced Vehicle Control*, AVEC 14, 2014.
- [19] David Lenz, Tobias Kessler, and Alois Knoll. Stochastic model predictive controller with chance constraints for comfortable and safe driving behavior of autonomous vehicles. In *IEEE Intelligent Vehicles Symposium, Proceedings*, volume 2015-August, pages 292–297, 2015.
- [20] Bilin Aksun Guvenc, Bilin Aksun Güvenç, and Sertaç Karaman. Robust yaw stability controller design and hardware-in-the-loop testing for a road vehicle. *Vehicular Technology, IEEE Transactions on*, 58(2):555–571, 2009.
- [21] Craig Earl Beal and J. Christian Gerdes. Model predictive control for vehicle stabilization at the limits of handling. *IEEE Transactions on Control Systems Technology*, 21(4):1258–1269, 2013.
- [22] Eduardo F. Camacho and Carlos Bordons Alba. *Model predictive control*. Springer Science & Business Media, 2013.
- [23] C. Hatipoglu, U. Ozguner, and K. A. Redmill. Automated lane change controller design. *IEEE Transactions on Intelligent Transportation Systems*, 4(1):13–22, March 2003.
- [24] Gonzalo Guerrero Salazar. Consideraciones teóricas para el diseño y análisis de la suspensión para el vehículo FSAE 2012. Master’s thesis, June 2015.

-
- [25] P. Falcone, F. Borrelli, J. Asgari, H.E. Tseng, and D. Hrovat. Predictive Active Steering Control for Autonomous Vehicle Systems. *IEEE Transactions on Control Systems Technology*, 15(3):566–580, May 2007.
- [26] Massimo Guiggiani. *The Science of Vehicle Dynamics*. Springer Netherlands, Dordrecht, 2014.
- [27] Rajesh Rajamani. *Vehicle dynamics and control*. Springer Science & Business Media, 2011.
- [28] David G. David G. Luenberger. Introduction to dynamic systems; theory, models, and applications. Technical report, 1979.
- [29] Dieter Schramm, Manfred Hiller, and Roberto Bardini. *Vehicle Dynamics*. Springer Berlin Heidelberg, Berlin, Heidelberg, 2014.
- [30] B. A. Guvenc and E. Kural. Adaptive cruise control simulator: a low-cost, multiple-driver-in-the-loop simulator. *IEEE Control Systems*, 26(3):42–55, June 2006.
- [31] Matthias Gerdt. Solving mixed-integer optimal control problems by Branch&Bound: A case study from automobile test-driving with gear shift. *Optimal Control Applications and Methods*, 26(1):1–18, 2005.
- [32] Modeling an Automatic Transmission Controller - MATLAB & Simulink Example.
- [33] Jin Xu, Kui Yang, YiMing Shao, and GongYuan Lu. An experimental study on lateral acceleration of cars in different environments in Sichuan, Southwest China. *Discrete Dynamics in Nature and Society*, 2015, 2015.
- [34] L. L. Hoberock. A survey of longitudinal acceleration comfort studies in ground transportation vehicles. *Journal of Dynamic Systems, Measurement, and Control*, 99(2):76–84, 1977.
- [35] Christopher B. Winkler. Inertial Properties of Commercial Vehicles. Technical report, 1981.
- [36] Tomer Toledo and David Zohar. Modeling duration of lane changes. *Transportation Research Record: Journal of the Transportation Research Board*, 2007.
- [37] Sterling J. Anderson, Steven C. Peters, Tom E. Pilutti, and Karl Iagnemma. An optimal-control-based framework for trajectory planning, threat assessment, and semi-autonomous control of passenger vehicles in hazard avoidance scenarios. *International Journal of Vehicle Autonomous Systems*, 8(2):190–216, 2010.
- [38] Simon Haykin. *Neural Networks: A Comprehensive Foundation*. Prentice Hall PTR, Upper Saddle River, NJ, USA, 2nd edition, 1998.

- [39] Brian DO Anderson and John B. Moore. *Optimal control: linear quadratic methods*. Courier Corporation, 2007.