



Casa abierta al tiempo

UNIVERSIDAD AUTÓNOMA METROPOLITANA
UNIDAD IZTAPALAPA

POSGRADO EN CIENCIAS Y TECNOLOGÍAS DE LA
INFORMACIÓN

**DETECCIÓN DE EVENTOS DE CONDUCCIÓN EN
VEHÍCULOS TERRESTRES POR MEDIO DE SENSORES
INERCIALES**

IDÓNEA COMUNICACIÓN DE RESULTADOS QUE PARA OPTAR EL GRADO DE
MAESTRO EN CIENCIAS Y TECNOLOGÍAS DE LA INFORMACIÓN
PRESENTA

OSCAR HUERTA SOLIS

Asesores: Dr. LUIS MARTÍN ROJAS CÁRDENAS
M. en C. GONZALO VÍCTOR ROJAS CÁRDENAS

Jurado: Dr. ROGELIO REYES REYES 
Dr. PEDRO LARA VELÁZQUEZ 
Dr. LUIS MARTÍN ROJAS CÁRDENAS 

Presidente
Secretario
Vocal

Ciudad de México, diciembre de 2019

La simplicidad es la máxima sofisticación.

Leonardo da Vinci (1452 –1519)

AGRADECIMIENTOS

En primer lugar, deseo expresar mi agradecimiento a los asesores de este trabajo de investigación, Dr. Luis Martín Rojas Cárdenas y M. en C. Gonzalo Víctor Rojas Cárdenas, por la dedicación y apoyo que han brindado a este estudio, por el respeto a mis sugerencias e ideas y por la dirección y el rigor que han facilitado a las mismas. Gracias por la confianza ofrecida desde que llegué a esta universidad.

Asimismo, agradezco a mis compañeros de generación de Maestría su apoyo personal y humano, especialmente a Sergio Javier Álvarez, Aurelio Nicolás Mata y Juan Daniel Vera González, con quien he compartido proyectos e ilusiones durante estos años.

El inicio de una nueva etapa académica requiere de la motivación proporcionada por quienes han tenido un impacto significativo en nuestra vida. En este caso mi más sincero agradecimiento al Dr. Enrique Rodríguez de la Colina. Gracias por su amabilidad, motivación y consejos.

Por el tiempo dedicado y atención, así como por las sugerencias recibidas y por la revisión cuidadosa que ha realizado de este texto, mi agradecimiento al Dr. Rogelio Reyes Reyes de la Escuela Superior de Ingeniería Mecánica y Eléctrica Unidad Culhuacán del Instituto Politécnico Nacional.

Pero un trabajo de investigación es también fruto del reconocimiento y del apoyo vital que nos ofrecen las personas que nos estiman, sin el cual no tendríamos fuerza y energía que nos anima a crecer como personas y como profesionistas.

Gracias a mi familia, a mis padres José Joel Huerta Luna y Carolina Solís Guzmán, a mi hermana Liliana Huerta Solís y a mi tía Rosa Solís Guzmán, quienes me acompañaron, apoyaron y animaron durante mis estudios de Maestría.

Gracias a mis amigos, Hortensia Cristina Cuevas Papalotzin, José de Jesús Espinoza Sandoval, Enrique Rincón Vázquez y Sergio Javier Álvarez que siempre me han prestado su gran apoyo moral y humano, necesarios en los momentos difíciles de este trabajo y esta profesión.

A todos, muchas gracias.

RESUMEN

Los accidentes de tránsito pueden provocar pérdidas humanas y materiales en todo el mundo. Debido a esto diferentes entidades en cada sociedad intentan reducir el problema a través de distintos mecanismos, entre los cuales se encuentran los sistemas de evaluación automática de hábitos de conducción. Una parte fundamental en algunos de estos sistemas es la detección de eventos básicos tales como vueltas, frenado y aceleración. En éste documento se presenta un sistema para la detección de eventos de conducción por medio de sensores inerciales. La detección se realiza en dos partes: Primero, se ubica un posible evento por medio de la Media Móvil Simple (SMA) del flujo de información entregado por los sensores. Segundo, el posible evento se compara con un conjunto de eventos básicos representativos que llamamos “referencia” y el proceso de comparación emplea los algoritmos de Distorsión de Tiempo Dinámico (DTW) y K-Vecinos más Cercanos (KNN). En nuestro sistema, se destaca el reconocimiento de dos eventos característicos que no han sido considerados anteriormente por otros autores, específicamente la ocurrencia de topes y baches, los cuales son poco habituales en países desarrollados. Por otra parte, los algoritmos DTW y KNN, al no demandar gran cantidad de poder de cómputo, son capaces de operar rápidamente y con ello la implementación pudo ser llevada a cabo en una computadora embebida Raspberry PI con sensores de movimiento del tipo sistemas micro-electro mecánicos (MEMS), la cual se puede colocar en el tablero de un automóvil.

ÍNDICE GENERAL

0.1. Lista de Figuras.....	11
0.2. Lista de Tablas.....	15
0.3. Lista de Abreviaturas.....	17
0.4. Introducción General.....	19
0.5. Objetivo General.....	23
0.6. Objetivos Particulares.....	23
0.7. Alcances y Limitaciones.....	24
1. CLASIFICACIÓN DE EVENTOS DE CONDUCCIÓN.....	25
1.1. Introducción.....	25
1.2. Esquema General de Clasificación de Eventos de Conducción.....	26
1.3. Estado del Conocimiento.....	27
1.3.1. Trabajos Relacionados con Algoritmos de Aprendizaje Maquinal.....	28
1.3.2. Trabajos Relacionados con otros Métodos de Clasificación.....	29
1.3.3. Observaciones del Estado del Conocimiento.....	30
2. SISTEMA AUTOMÁTICO DE CLASIFICACIÓN.....	33
2.1. Metodología.....	33
2.2. Base de Registros de Eventos de Conducción.....	34
2.2.1. Protocolo de Adquisición de Muestras.....	36
2.3. Preprocesamiento de las Muestras.....	38
2.3.1. Extracción de Rasgos Característicos.....	39
2.3.2. Filtro de Media Móvil (MAF).....	52
2.4. Algoritmos de Clasificación.....	55
2.4.1. Distorsión de Tiempo Dinámico (DTW).....	56
2.4.2. K-Vecinos más Cercanos (KNN).....	60
2.4.3. Combinación de DTW y KNN para la Clasificación.....	62
3. IMPLEMENTACIÓN Y DESEMPEÑO DEL SISTEMA.....	65
3.1. Implementación del Sistema.....	65
3.2. Segmentación Automática de Eventos de Interés.....	67
3.3. Resultados del Sistema.....	72
3.3.1. Pruebas y Resultados.....	72
3.3.2. Comparación de Resultados.....	77
4. CONCLUSIONES Y TRABAJO FUTURO.....	79
4.1. Conclusiones.....	79
4.2. Trabajo Futuro.....	81

A. ANEXO 1	83
A.1. Comparación de Sistemas MEMS.....	83
A.2. Comparación de Computadoras Embebidas.....	85
B. ANEXO 2	87
B.1. Ejemplos de Gráficas que Representan a los Eventos de Conducción.....	87
REFERENCIAS	125

0.1. LISTA DE FIGURAS

Figura 1.1: Esquema general de un sistema de clasificación de eventos de conducción.....	27
Figura 2.1: Metodología para implementar un clasificador y un sistema mediante DTW y KNN. Las flechas continuas muestran el orden de aplicación de cada etapa. La flecha punteada muestra la dependencia de los modelos de referencia al evaluar el sistema.....	34
Figura 2.2: Orientación de los ejes x, y, z de la aceleración, velocidad angular y ángulo de giro respecto al automóvil. Imagen modificada de https://www.freepik.com	36
Figura 2.3: Gráfica de la aceleración en el eje y (A_y) para el evento Frenar.....	40
Figura 2.4: Gráfica del ángulo de giro en el eje x (E_x) para el evento Frenar, relativo a la dirección en donde se detectó el inicio del evento.....	40
Figura 2.5: Gráfica de la aceleración en el eje y (A_y) para el evento Acelerar.....	41
Figura 2.6: Gráfica del ángulo de giro en el eje x (E_x) para el evento Acelerar, relativo a la dirección en donde se detectó el inicio del evento.....	41
Figura 2.7: Gráfica de la velocidad angular en el eje z (G_z) para el evento Vuelta a la izquierda.....	42
Figura 2.8: Gráfica del ángulo de giro en el eje z (E_z) para el evento Vuelta a la izquierda, relativo a la dirección en donde se detectó el inicio del evento.....	42
Figura 2.9: Gráfica de la velocidad angular en el eje z (G_z) para el evento Vuelta a la derecha.....	43
Figura 2.10: Gráfica del ángulo de giro en el eje z (E_z) para el evento Vuelta a la derecha, relativo a la dirección en donde se detectó el inicio del evento.....	43
Figura 2.11: Gráfica de la velocidad angular en el eje z (G_z) para el evento Vuelta a la izquierda en U.....	44
Figura 2.12: Gráfica del ángulo de giro en el eje z (E_z) para el evento Vuelta a la izquierda en U, relativo a la dirección en donde se detectó el inicio del evento.....	44
Figura 2.13: Gráfica de la velocidad angular en el eje z (G_z) para el evento Vuelta a la derecha en U.....	45

Figura 2.14: Gráfica del ángulo de giro en el eje z (E_z) para el evento Vuelta a la derecha en U, relativo a la dirección en donde se detectó el inicio del evento.....	45
Figura 2.15: Gráfica de la aceleración en el eje z (A_z) para el evento Tope.....	46
Figura 2.16: Gráfica de la velocidad angular en el eje x (G_x) para el evento Tope.....	46
Figura 2.17: Gráfica de la aceleración en el eje z (A_z) para el evento Bache.....	47
Figura 2.18: Gráfica de la velocidad angular en el eje x (G_x) para el evento Bache.....	47
Figura 2.19: Respuesta en frecuencia del filtro de media móvil. La media móvil tiene bajo rendimiento como filtro paso bajo, debido a su caída lenta y a la insuficiente banda de atenuación.....	53
Figura 2.20: Un ejemplo de la utilidad de la distorsión de tiempo dinámico. A) Dos secuencias que, si bien tienen una forma general similar, no están alineadas en el eje del tiempo. Una medida de distancia que asume que el i -ésimo punto en una secuencia está alineado con el i -ésimo punto en la otra producirá una desemejanza. B) DTW puede encontrar una alineación entre las dos secuencias que permita calcular una medida de distancia o similitud más sofisticada.....	56
Figura 2.21: Ejemplo de una matriz de distancias y su respectivo camino deformado.....	58
Figura 2.22: Representación pictográfica de dos alternativas de patrones de paso: A) Patrón correspondiente a: $\gamma(i, j) = d(i, j) + \min\{\gamma(i - 1, j - 1), \gamma(i - 1, j), \gamma(i, j - 1)\}$ B) Patrón correspondiente a: $\gamma(i, j) = d(i, j) + \min\{\gamma(i - 1, j - 1), \gamma(i - 1, j - 2), \gamma(i - 2, j - 1)\}$	59
Figura 2.23: Gráfica de la velocidad angular máxima contra el ángulo total de giro de los vectores de características de referencia de los eventos de conducción en todas las categorías. Los puntos marcados con “No vuelta” son eventos pertenecientes a las categorías “Velocidad” y Camino” indistintamente.....	63
Figura 2.24: Diagrama de flujo del clasificador de dos etapas.....	64
Figura 3.1: Sistema para el almacenamiento de muestras de aceleración, velocidad angular y ángulo de inclinación: A) Computadora embebida Raspberry PI 3B, B) Modulo Bluetooth y sensor MEMS.....	66

Figura 3.2: Sistema para el almacenamiento de muestras, colocado en el parabrisas del automóvil.....	66
Figura 3.3: Aplicación <i>Serial Bluetooth Terminal</i> para el envío y recepción de comandos con el sistema de almacenamiento.....	67
Figura 3.4: Tasa de segmentación o reconocimiento para los eventos de la categoría “Velocidad”. Frenar: $SMA_F = 0.038g$, Acelerar: $SMA_A = 0.026g$	69
Figura 3.5: Tasa de segmentación o reconocimiento para los eventos de la categoría “Vueltas”. Vuelta a la izquierda: $SMA_{VI} = 260^\circ/s$, Vuelta a la derecha: $SMA_{VD} = 190^\circ/s$. Vuelta a la izquierda en U: $SMA_{VIU} = 670^\circ/s$, Vuelta a la derecha en U: $SMA_{VDU} = 670^\circ/s$	70
Figura 3.6: Tasa de segmentación o reconocimiento para los eventos de la categoría “Camino”. Tope: $SMA_T = 0.021g$, Bache: $SMA_B = 0.0076g$	71
Figura 3.7: Tasa de aciertos respecto al valor de K al utilizar únicamente DTW y KNN.....	73
Figura 3.8: Matriz de confusión de la mejor tasa de clasificación del 74% al utilizar únicamente DTW y KNN.....	73
Figura 3.9: Tasa de aciertos respecto al valor de K en el segundo clasificador, al utilizar Estadística descriptiva con KNN y DTW-KNN.....	74
Figura 3.10: Matriz de confusión de la mejor tasa de clasificación del 100% al utilizar Estadística descriptiva con KNN y DTW-KNN.....	75
Figura 3.11: Tasa de aciertos respecto al valor de K en el segundo clasificador, al utilizar Estadística descriptiva con KNN, DTW-KNN y Segmentación automática.....	76
Figura 3.12: Matriz de confusión de la mejor tasa de clasificación del 94% al utilizar Estadística descriptiva con KNN, DTW-KNN y Segmentación automática.....	77
Figura B.1 a B.72: Gráficas de la aceleración, velocidad angular y ángulo de giro en los ejes x , y , z para los diferentes eventos de conducción.....	87-123

0.2. LISTA DE TABLAS

Tabla 1.1: Principales investigaciones sobre sistemas de clasificación de eventos de conducción.....	28
Tabla 2.1: Eventos de conducción que pertenecen a las diferentes categorías.....	39
Tabla 2.2: Observaciones de las magnitudes que describen de mejor manera los eventos de conducción de la categoría Velocidad.....	48
Tabla 2.3: Observaciones de las magnitudes que describen de mejor manera los eventos de conducción de la categoría Vueltas.....	48
Tabla 2.4: Observaciones de las magnitudes que describen de mejor manera los eventos de conducción de la categoría Camino.....	49
Tabla 2.5: Vectores de características que pertenecen a las diferentes categorías, donde: A_y = aceleración en el eje y , E_x = ángulo de giro en el eje x , G_z = velocidad angular en el eje z , E_z = ángulo de giro en el eje z , A_z = aceleración en el eje z y G_x = velocidad angular en el eje x , Los subíndices p y s indican vector primario y secundario respectivamente.....	50
Tabla 2.6: Número de registros de vectores de características en la base de datos de referencia.....	51
Tabla 3.1: Magnitudes B_a y umbrales de detección <i>SMA</i> por cada evento de conducción.....	71
Tabla 3.2: Comparación de los resultados obtenidos por este trabajo contra diferentes investigaciones sobre la clasificación de eventos de conducción.....	78
Tabla A.1: Comparación entre diferentes sistemas MEMS.....	83
Tabla A.2: Comparación entre diferentes computadoras embebidas.....	85

0.3. LISTA DE ABREVIATURAS

ADAS	Sistemas Avanzados de Asistencia al Conductor
LDW	Sistema de Aviso de Cambio de Carril
ESP	Programa de Estabilidad Electrónico
OBD	Diagnóstico a Bordo
CAN	Controlador de Área Local
GPS	Sistema de Posicionamiento Global
MEMS	Sistemas Micro-Electro Mecánicos
IIR	Respuesta Infinita al Impulso
FIR	Respuesta Finita al Impulso
MAF	Filtro de Media Móvil
SMA	Media Móvil Simple
CDTW	Distorsión de Tiempo Dinámico Continuo
DTW	Distorsión de Tiempo Dinámico
NNR	Vecinos más Cercanos
KNN	K-Vecinos más Cercanos
SVM	Máquinas de Soporte Vectorial
HMM	Modelos Ocultos de Markov

0.4. INTRODUCCIÓN GENERAL

Con el creciente desarrollo económico, la posesión de vehículos en todo el mundo se ha multiplicado en los últimos años. Desafortunadamente, de la mano con éste crecimiento se observa un incremento en la congestión vial, ya que aumenta el número de vehículos, lo cual acrecienta los problemas de la seguridad de tránsito y por consiguiente un mayor número de accidentes. Las estadísticas publicadas por el Instituto Nacional de Estadística y Geografía muestran que a fines de mayo de 2018 existían poco menos de 48 millones de vehículos en México [1]. Además, alrededor de 5 mil personas mueren y más de 100 mil personas resultan heridas en accidentes de tránsito cada año y más del noventa por ciento de los accidentes mortales son causados por un comportamiento inadecuado de manejo [2]. En algunas circunstancias, los conductores prudentes pueden sufrir las consecuencias de las acciones de aquellos que no toman de forma seria la responsabilidad de conducir e incluso de aquellos que se involucran en conductas agresivas con fines de diversión. Para identificar conductores agresivos y reducir este fenómeno, varios autores [3-7] han discutido y enfatizado el reconocimiento de conductas típicas de conducción. Aparentemente, reconocer los comportamientos de los conductores (incluyendo conductas normales y de conducción agresivas), registrando sus patrones de conducción y proporcionando información sobre sus conductas puede ayudar a promover una conducción más segura, reducir accidentes de tránsito y contribuir a la seguridad social.

Con éste fin, fabricantes de automóviles están instalando sistemas avanzados de asistencia al conductor (ADAS) en algunos automóviles de gama alta con el objetivo de balancear la seguridad y la eficiencia del tránsito [8]. El ADAS se compone principalmente de un programa de estabilidad electrónico (ESP), un sistema de control de crucero adaptativo y un sistema de aviso de cambio de carril (LDW) [9]. El costo relativamente alto de cada parte limita la implementación de ADAS en automóviles económicos los cuales constituyen la mayoría de los automóviles en el camino. Además, los ADAS se enfocan principalmente en la asistencia de conducción en lugar de evaluar el estilo de conducción.

Similar a los ADAS, los autores en [10, 11] discutieron y resumieron varios enfoques para reconocer conductas de manejo y monitorear a los conductores, para esto emplearon señales híbridas (incluyendo señales tomadas de video, micrófonos, GPS, presión atmosférica y sensores inerciales). Sin embargo, cuando se toma como entrada de los sistemas de reconocimiento del comportamiento de conducción [5, 7], estas señales son difíciles de transmitir y procesar, lo que aumenta la complejidad computacional y afecta la automatización del sistema. En consecuencia, el uso de esta información puede ser difícil en cierta medida [12]. Además, se ha demostrado que las señales proporcionadas por sensores inerciales pueden cumplir con los requisitos de reconocimiento de diferentes conductas de conducción [3, 4, 6, 12-14].

En general, hay dos maneras diferentes en que los investigadores obtienen información dinámica sobre vehículos en movimiento: el bus del controlador de área de red (CAN) y los sistemas micro-electro mecánicos (MEMS). Un bus CAN es un bus vehicular estándar para facilitar la comunicación entre microcontroladores y dispositivos sin una computadora anfitrión [15], y lleva

todos los datos necesarios para describir el estado de un automóvil [13]. A través del puerto de diagnóstico a bordo (OBD) en los vehículos, las personas pueden tener acceso muy limitado a la información del bus CAN. Por otro lado, en años recientes los MEMS han crecido rápidamente en popularidad, haciéndose de tamaño más pequeño, más liviano y con menor consumo de energía, lo que hace posible integrar diferentes unidades de sensores como acelerómetros, giroscopios, magnetómetros, termómetros, entre otros en un solo circuito integrado. Montado en la cabina de un automóvil, un sistema MEMS puede proporcionar a las personas de información crucial sobre el automóvil en movimiento [13]. Los sensores de movimiento y los teléfonos inteligentes se encuentran entre las aplicaciones típicas de los sistemas MEMS.

Aunque el bus CAN lleva todas las señales del vehículo, la información que las personas pueden extraer a través de un puerto OBD es limitada, ya que los fabricantes de automóviles prefieren no divulgar al público el protocolo privado del puerto OBD, principalmente por consideraciones de propiedad intelectual y seguridad del vehículo. Además, algunas investigaciones han revelado que se puede acceder a diferentes componentes del vehículo a través del puerto OBD [16, 17], lo que podría permitir a personas malintencionadas la posibilidad de controlar los sistemas de un vehículo. En consecuencia, los productos que tienen acceso al puerto OBD pueden representar una amenaza para el vehículo y la seguridad humana en cierta medida. Además, el trabajo en [13] ha mostrado que el uso de los datos del bus CAN para detectar diversos eventos de conducción, generó un menor rendimiento que el de un dispositivo portátil del tipo Tablet. Por lo tanto, en el proceso de reconocimiento del comportamiento de conducción, la plataforma de recopilación de datos es más apropiada si tiene como base un sistema MEMS en lugar del puerto OBD y el bus CAN.

Con la proliferación de teléfonos inteligentes, la explotación de los recursos de estos se ha vuelto cada vez más popular. En algunos casos, los investigadores utilizaron teléfonos inteligentes como plataformas de sensores y presentaron algunos resultados satisfactorios [4, 7, 18]. Aunque los teléfonos y los sensores de movimiento están integrados con un sistema MEMS, funcionan de manera diferente en términos de reconocimiento del comportamiento de conducción ya que sus características varían entre modelos de teléfonos. Debido a que los teléfonos inteligentes están integrados con diferentes sensores, que en gran medida proporcionan una mejor interacción entre el dispositivo y el ser humano, cuando se asignan más recursos computacionales al reconocimiento del comportamiento de conducción, los teléfonos pueden experimentar un retraso que puede dar como resultado una experiencia negativa para el usuario. Por otra parte, diferentes modelos de teléfonos pueden estar equipados con diferentes tipos de sistemas MEMS y, como tal, cada uno se desempeñará de manera diferente aun teniendo el mismo algoritmo de reconocimiento del comportamiento de conducción. Además, los conductores utilizan los teléfonos inteligentes principalmente para la asistencia en la navegación y la comunicación cuando conducen, lo que puede interrumpir los procesos de reconocimiento y realimentación dentro del sistema. Por lo que utilizar sensores de movimiento MEMS dedicados es una mejor opción ya que el acelerómetro, giroscopio y magnetómetro, entre otros, son suficientes para identificar diferentes comportamientos de manejo sin que ocupen más recursos de un procesador. En comparación con los teléfonos inteligentes, los sensores de movimiento dedicados son en su mayoría de bajo costo, se desempeñan de manera más adecuada y logran una mayor precisión en el proceso de reconocimiento del comportamiento de conducción [3].

Debido a lo anterior un sistema de reconocimiento del comportamiento de conducción con base en sensores de movimiento MEMS dedicados [3, 6, 23] proporciona mejores resultados en comparación con el uso de los sensores de movimiento de un teléfono inteligente, esto debido a que se pueden caracterizar y modificar diferentes parámetros de los sensores, como por ejemplo la velocidad de obtención de muestras de aceleración y con ello se tiene mayor certeza de su funcionamiento y sus limitantes. Además de que el sistema al realizar únicamente la tarea de reconocer el comportamiento de conducción tiene la posibilidad de hacerlo en el menor tiempo posible.

De esta forma el objetivo general de la aplicación que se presenta en este trabajo consiste en la implementación y evaluación del desempeño de un sistema de detección de eventos de conducción, basado en sensores de movimiento MEMS dedicados que conforman una plataforma de recopilación de datos, además de que el sistema de clasificación de eventos utiliza los algoritmos de aprendizaje maquina Distorsión de Tiempo Dinámico (DTW) y K-Vecinos más Cercanos (KNN). Lo anterior con el propósito de obtener un sistema que proporcione mejores resultados que los obtenidos con un teléfono inteligente o el puerto OBD con el bus CAN, además de que se podrán obtener resultados en el menor tiempo posible debido al bajo costo computacional de los algoritmos DTW y KNN, contrastado con otros trabajos que utilizan Modelos Ocultos de Markov (HMM) [3]. Esta implementación debe tratar, principalmente, con la variabilidad de la conducción de una persona, con la influencia de factores intrínsecos (como los de los sensores MEMS) y con el ruido presente en el vehículo. De igual forma debe considerar aspectos relacionados con la caracterización de los eventos de conducción, así como su procesamiento llegando hasta la conformación de un método. Un objetivo adicional es la evaluación del sistema, para ello se requiere comparar su desempeño con el obtenido por otros trabajos relacionados al tema de estudio. La comparación del desempeño requiere analizar la tasa de clasificaciones correctas obtenida en los sistemas, lo cual permite caracterizar su comportamiento.

Con base en los objetivos planteados, este documento se estructura de la siguiente forma:

En el primer capítulo se establece el contexto en el que se desarrolla éste trabajo, entre ellos un esquema general sobre los sistemas de detección de eventos de conducción. También un estado del conocimiento sobre trabajos relacionados en el reconocimiento de hábitos de conducción o estilos de manejo, el cual hace énfasis en sus características principales y destaca sus parámetros de desempeño. En el capítulo 2 se describe la conformación de una base de registros de eventos de conducción propia que considera diferentes aspectos de la variabilidad de los eventos y permite la operación de un sistema de reconocimiento. Posteriormente se expone el preprocesamiento al que son sometidos los registros de eventos, hasta la obtención de los llamados vectores de características, los cuales sintetizan las características para cada evento de conducción. Se finaliza este capítulo con una descripción de la teoría en la que se basan los algoritmos de Distorsión de Tiempo Dinámico (DTW) y K-Vecinos más Cercanos (KNN) como una técnica que permite la clasificación o separación de conjuntos de vectores de características. En el capítulo 3 se describe la implementación del sistema, las pruebas que lo evalúan y se comparan los resultados con otras propuestas. Por último, en el capítulo 4, se dan las conclusiones pertinentes y las actividades que pueden derivar de forma inmediata del presente trabajo.

0.5. OBJETIVO GENERAL

Implementar y evaluar el desempeño de un sistema de detección de eventos de conducción mediante sensores inerciales del tipo acelerómetro y giroscopio, considerando las magnitudes físicas de aceleración, velocidad angular y ángulo de giro de los eventos.

0.6. OBJETIVOS PARTICULARES

1. Diseñar y construir un sistema dedicado para la adquisición de muestras de aceleración y velocidad angular, independiente del automóvil
2. Adoptar la postura de Conducción Natural [27] para obtener mediciones lo más próximas a situaciones reales de conducción
3. Detectar eventos no considerados anteriormente en trabajos relacionados al tema de estudio, en específico identificar la ocurrencia de Topes y Baches
4. Utilizar la combinación de los algoritmos DTW y KNN para realizar la clasificación de los eventos
5. Proponer un sistema de detección de eventos de conducción que obtenga resultados en el menor tiempo posible, mediante el uso de algoritmos y métodos de bajo costo computacional

0.7. ALCANCES Y LIMITACIONES

Para desarrollar este trabajo se emplea un marco controlado de experimentación, el cual no incluye, ni todos los tipos de eventos de conducción, ni todas las condiciones posibles en que puedan ocurrir, así, el marco considerado es el siguiente:

- a) Se consideran únicamente vehículos terrestres del tipo automóvil sedán, en condiciones mecánicas normales. No se consideran autobuses de pasajeros o camiones de carga, entre otros
- b) Los eventos a detectar se deben poder identificar mediante sensores inerciales del tipo acelerómetro y giroscopio
- c) No se consideran caminos de terracería o empedrados, únicamente trayectos con carpeta de asfalto o concreto hidráulico, bajo las condiciones de las calles de la Ciudad de México

CAPÍTULO 1

CLASIFICACIÓN DE EVENTOS DE CONDUCCIÓN

1.1. INTRODUCCIÓN

El reconocimiento de eventos de conducción es un área que depende en gran parte del procesamiento de señales, de la cual nos apoyamos para efectuar la segmentación y el preprocesamiento de los eventos de conducción, dichos conceptos son descritos a continuación:

Segmentación: Consiste en determinar a partir de diferentes magnitudes físicas y ciertos criterios de detección, el inicio y fin de la posible ocurrencia de un evento de conducción; el evento proporciona las magnitudes al sistema el cual determina su ocurrencia o si éste no cumple con los criterios de detección.

Preprocesamiento: Consiste en adecuar las señales provenientes de diferentes magnitudes físicas para su uso en etapas posteriores; el evento proporciona las magnitudes al sistema el cual resalta características específicas.

Existe trabajo considerable reportado tanto en universidades como en la industria [25, 26], sin embargo, la mayor parte de la investigación se ha encaminado únicamente al desarrollo de modelos de clasificadores de eventos de conducción, esto quiere decir que no incluyen una etapa de segmentación automática, la cual puede reducir la tasa de eventos detectados correctamente. Por la naturaleza de este trabajo, resulta de interés describir los antecedentes que se tienen en materia de clasificación de eventos de conducción.

1.2. ESQUEMA GENERAL DE CLASIFICACIÓN DE EVENTOS DE CONDUCCIÓN

En general los sistemas de clasificación actuales pueden describirse mediante cuatro módulos: adquisición, segmentación, preprocesamiento y clasificación [7, 18, 23].

Adquisición: En esta fase se consideran aspectos sobre la adquisición de muestras de información de aceleración y velocidad angular que representan eventos de conducción. Actualmente se utilizan sensores de movimiento MEMS que pueden entregar información en un intervalo de 25 a 200 muestras por segundo. La frecuencia de obtención de muestras es asignada de acuerdo a la calidad de las señales de aceleración y velocidad angular a utilizar en las etapas posteriores del sistema de clasificación, con el objetivo de obtener la mayor tasa de clasificaciones correctas.

Segmentación: En esta fase se considera la detección de un posible evento de conducción para posteriormente ser preprocesado y clasificado. Previo a clasificar un evento, se debe detectar el inicio y fin de la posible ocurrencia del mismo, esto con el objetivo de evitar el sobre procesamiento en las etapas de preprocesamiento y clasificación y con ello aumentar la tasa de eventos clasificados correctamente.

Preprocesamiento: En esta fase se considera la extracción de características descriptivas de las muestras de aceleración y velocidad angular de los eventos de conducción, que permitirán la operación del sistema de clasificación. La extracción de vectores de características es realizada por medio del análisis en el tiempo de las muestras o por estadística descriptiva. Una fase que puede realizarse posteriormente es la reducción del ruido en los vectores de características por medio de filtros, por ejemplo, los de Respuesta Finita al Impulso (FIR).

Clasificación: En esta fase se considera el proceso de generación de los modelos correspondientes a cada evento de conducción y la metodología para realizar la evaluación de los datos característicos con el objetivo de determinar la mejor correspondencia con los modelos. Con este fin son empleados distintos procedimientos matemáticos. Algunos de los más referidos en los artículos de investigación son las Máquinas de Soporte Vectorial (SVM) [13] ya que son capaces de clasificar objetos conformados por información de alta dimensionalidad y los Modelos Ocultos de Markov (HMM) [3] que consideran diversos segmentos de las secuencias temporales como los diferentes estados del modelo. También es reportado como procedimiento matemático el algoritmo de agrupamiento K-Means [12] que puede particionar el conjunto de observaciones en diferentes grupos.

La figura 1.1 muestra un esquema de un sistema de clasificación general. En él se identifican los cuatro módulos descritos previamente: adquisición, segmentación, preprocesamiento y clasificación.

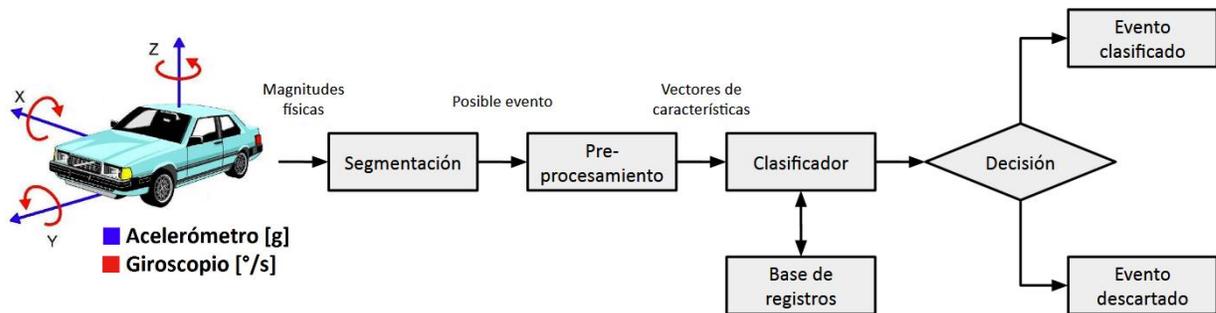


Figura 1.1: Esquema general de un sistema de clasificación de eventos de conducción.

1.3. ESTADO DEL CONOCIMIENTO

En la tabla 1.1 se muestran las principales investigaciones sobre el reconocimiento de eventos de conducción con la mejor tasa de clasificación. En esta tabla se muestran las diferentes categorías de eventos detectados, algoritmos de aprendizaje maquina utilizados, la plataforma de adquisición de datos y si el tipo de investigación considera la segmentación de posibles eventos de conducción, además de la generación del modelo correspondiente. En la columna de clasificación correcta se muestra la mejor tasa de clasificación obtenida utilizando un algoritmo de aprendizaje maquina.

A pesar de que la información presentada en la tabla 1.1 no es suficiente para identificar características particulares sobre cada una de las implementaciones, como por ejemplo la metodología de pruebas realizadas, es posible establecer una tendencia, la cual consiste en la mejora de la tasa de clasificación de los sistemas, conjuntamente con el costo del incremento en las dimensiones de las bases de registros de eventos de conducción empleadas, aspecto que puede considerarse natural, dado el desarrollo que a la par se ha suscitado en los sensores de movimiento MEMS para las velocidades de obtención de muestras y la densidad de información que proporcionan. Aún con estas mejoras en el desempeño, la existencia de un porcentaje de error conduce al uso de sistemas auxiliares en aplicaciones donde se requiere o desea una mayor confiabilidad. Dichos sistemas auxiliares pueden consistir, por ejemplo, en visión por computadora que proporcione redundancia en los sistemas de reconocimiento. En la práctica, se sabe que siempre existe la posibilidad de tener error en cualquier tarea de reconocimiento, sin embargo, se desea minimizarla.

AUTORES	TRABAJO REALIZADO	CATEGORÍAS DETECTADAS	ADQUISICIÓN DE DATOS	MÉTODO DE CLASIFICACIÓN	CLASIFICACIÓN CORRECTA
Mitrovic, 2005 [3]	Clasificación	Velocidad Vueltas Glorieta	Sistema embebido (MEMS)	HMM	98%, HMM
Jhonson, et. al., 2011 [7]	Segmentación y Clasificación	Velocidad Vueltas Carril	Teléfono Inteligente	DTW KNN	91%, DTW-KNN
Song, et. al., 2012 [18]	Segmentación y Clasificación	Velocidad Vueltas	Teléfono Inteligente	DTW KNN	93%, DTW-KNN
Sathyanarayana, et. al., 2012 [13]	Clasificación	Velocidad Vueltas Carril	Automóvil (OBD + CAN)	KNN SVM	81%, SVM
Ly, et. al., 2013 [12]	Clasificación	Velocidad Vueltas	Automóvil (OBD + CAN)	K-Means SVM	80%, K-Means
Minglin, et. al., 2016 [23]	Segmentación y Clasificación	Velocidad Vueltas Carril	Sistema embebido (MEMS)	KNN SVM	93%, SVM

Tabla 1.1: Principales investigaciones sobre sistemas de clasificación de eventos de conducción.

Sin lugar a dudas, los sistemas de reconocimiento de eventos de conducción pueden ayudar a los conductores a ser más cautelosos, dándoles realimentación sobre las maniobras de conducción que realizan en un trayecto y aún más, aumentar la seguridad en el camino ya que pueden integrarse junto con sistemas que además detectan el nivel de agresividad en los eventos [7]. Hay diversas investigaciones que se dedican al estudio de áreas relacionadas, como el reconocimiento del estilo de conducción, la clasificación del conductor, la conducción segura, entre otras. Con base en los métodos de clasificación utilizados, estos estudios se pueden dividir en dos categorías, una que se centra en algoritmos de aprendizaje maquina y otra que utiliza diversos métodos de detección.

1.3.1 TRABAJOS RELACIONADOS CON ALGORITMOS DE APRENDIZAJE MAQUINAL

Mitrovic desarrolló un sistema de reconocimiento de eventos de conducción utilizando Modelos Ocultos de Markov (HMM) utilizando los datos de aceleración longitudinal y lateral de un automóvil [3]. La limitada información proporcionada por la aceleración no posee la capacidad de describir otros cambios dinámicos que se reflejen completamente en la información recabada durante el proceso de movimiento del automóvil. Esa es la razón por la cual este trabajo solo puede reconocer eventos de conducción dentro de las tres categorías que se observan en la tabla 1.1, sin tener un mejor rendimiento en términos de precisión. B. Higgs y M. Abbas definieron el comportamiento del conductor como una función donde el estado del tráfico actual es el argumento y las acciones del conductor es la variable dependiente [19]. Este trabajo utilizó fragmentación y agrupamiento para descomponer la función en modelos tradicionales de seguimiento de automóviles y posteriormente en varias funciones diferentes. Con base en estas funciones, los investigadores definieron y evaluaron diferentes patrones de conducción. Johnson et. al. propuso un sistema MIROAD que apunta a reconocer el estilo de conducción utilizando los sensores incorporados en un teléfono inteligente [7]. Haciendo uso de la fusión de datos de un acelerómetro, giroscopio, magnetómetro, GPS y video, basado en el algoritmo de Distorsión de Tiempo Dinámico

(DTW) y K-Vecinos más Cercanos (KNN), el sistema MIROAD puede reconocer comportamientos de conducción agresivos y no agresivos. De manera similar, Song et. al. [18] reconoce el estilo de conducción empleando el algoritmo de Distorsión de Tiempo Dinámico (DTW) y utiliza los sensores de movimiento de un teléfono inteligente como plataforma de adquisición de datos. Sathyanarayana et. al. [13] hizo una comparación entre las señales del bus CAN y las señales de los sensores de un dispositivo portátil y concluyó que cuando se trata de reconocer una maniobra de conducción, hubo una mejora del 15% con datos recopilados por un dispositivo portátil. Además, este trabajo discutió la elección de las características y el rendimiento de KNN y SVM. Los autores han demostrado que el uso de la información de los sensores de un dispositivo portátil es mejor que la información del bus CAN obtenida a través de un puerto OBD en el dominio del reconocimiento del comportamiento de conducción. En [20], Wang et. al. resumió tres métodos para reconocer y estimar condiciones de manejo: técnicas basadas en GPS, análisis estadístico y cadenas de Markov. Con base en la información de la posición del pedal de aceleración y freno, los autores clasificaron a los conductores de acuerdo con tres estilos de conducción que fueron suave, normal y agresivo. Este trabajo se realizó para obtener un ahorro de combustible en vehículos eléctricos híbridos, sin embargo, la técnica con base en GPS tiene el inconveniente de no poder operar cuando el automóvil transita por un túnel o dentro de estacionamientos techados.

1.3.2. TRABAJOS RELACIONADOS CON OTROS MÉTODOS DE CLASIFICACIÓN

Un equipo internacional dirigido por Takeda et. al. equipó tres vehículos con numerosos sensores que incluyen cámaras, micrófonos, dispositivos OBD, GPS, sensores inerciales, sensores de presión, etc. [10]. Estas tres plataformas de obtención y transmisión de datos se pueden utilizar para monitorear a los conductores y determinar con precisión el estado del automóvil en movimiento, y que efectivamente ofreció un avance en la investigación sobre el comportamiento de conducción. Vaitkus et. al. [6] propuso un enfoque de reconocimiento de patrones para evaluar los estilos de conducción normales y agresivos utilizando análisis estadísticos de un acelerómetro, y discutieron la extracción de características en el dominio del tiempo, pero no incorporaron el reconocimiento de eventos de conducción en su trabajo. Fazeen et. al. [4] utilizó los datos del acelerómetro de un teléfono inteligente basado en Android para registrar y analizar el comportamiento de los conductores, incluida la aceleración, desaceleración y cambio de carriles. Sin embargo, este trabajo no clasificó comportamientos de manejo específicos. Haciendo hincapié en el reconocimiento de las condiciones de los caminos, los investigadores identificaron anomalías en la carretera y trazaron mapas de los segmentos experimentales. Doerr et. al. [21] desarrolló un sistema en línea para el reconocimiento de estilos de conducción utilizando lógica difusa. En lugar de recopilar datos en condiciones reales de tráfico, los autores utilizaron la plataforma CarMaker de IPG [24] para crear un modelo de control de vehículos y así generar datos que describan el movimiento de un automóvil. Además, este trabajo simuló señales de bus CAN, que tendrían algunas restricciones para la aplicación práctica. Dirigido a analizar los estados psicofisiológicos de los conductores, Rygula [22] desarrolló un método de identificación del estilo de conducción que utiliza el tacógrafo del automóvil para el análisis de la velocidad. Dai et. al. [14] utilizaron la información extraída del acelerómetro y los sensores de orientación integrados en los teléfonos

inteligentes para detectar la conducción en estado de ebriedad. Con base en su algoritmo, los autores compararon los datos recabados con muestras típicas de conductores ebrios para evaluar el estado de conducción de los conductores; además desarrollaron una aplicación para iPhone [5]. Con visión por computadora y métodos de reconocimiento de patrones, Bergasa et. al. utilizaron señales híbridas (incluidos video, voz, GPS y sensores inerciales) para detectar la falta de atención del conductor. La aplicación informaría los resultados calculados del conductor y evaluaría el proceso de conducción.

Cabe mencionar que los trabajos de investigación mencionados en las secciones 1.3.1 y 1.3.2 no sólo se han desarrollado en universidades o laboratorios, también en la industria se han patentado diferentes sistemas y métodos para monitorear e improvisar el comportamiento del conductor, así como para la asistencia en la conducción de un automóvil. Barke et. al. [25] por medio de Audi AG, empresa alemana fabricante de automóviles, patentó un método para que un sistema autónomo tome el control del automóvil cuando el conductor presenta fatiga, se distrae o tiene un comportamiento de conducción agresivo. Por medio de un arreglo de sensores pueden detectar, por ejemplo, las aceleraciones longitudinales y transversales del automóvil, así como la posición del volante. Oduor et. al. [26] mediante la empresa norteamericana IBM, fabricante de hardware y software para computadoras, patentó un sistema electrónico y métodos para detectar las condiciones y el contexto de la conducción, resultantes de conductores ejecutando maniobras peligrosas. Para su detección consideran varios sensores como GPS, el puerto OBD, acelerómetros, giroscopios, entre otros.

1.3.3 OBSERVACIONES DEL ESTADO DEL CONOCIMIENTO

Los principales métodos de detección de eventos son aquellos que pueden utilizar estadística descriptiva de las señales de los sensores de movimiento, como K-Means y SVM, y también los que trabajan con las secuencias temporales de las señales de los sensores, como DTW y HMM. En la columna de clasificación correcta de la tabla 1.1 se puede observar que los algoritmos DTW y HMM dominan las tasas de clasificación correcta sobre los que utilizan estadística descriptiva como SVM, lo cual nos indica que se obtienen mejores tasas de clasificación al utilizar directamente las señales de información de los sensores de movimiento junto con los algoritmos DTW y HMM, esto resulta natural, debido a que esos algoritmos fueron diseñados para trabajar con información de secuencias temporales.

Las principales plataformas de adquisición de datos utilizadas son:

- Teléfonos inteligentes
- Bus CAN mediante el puerto OBD del automóvil
- Sistemas embebidos con sensores de movimiento MEMS

Sin embargo, utilizando los datos del bus CAN para detectar diversos eventos de conducción, se genera un menor rendimiento que el de un teléfono inteligente o un sensor MEMS. Esto nos sugiere que la información de sensores de movimiento como acelerómetros y giroscopios incluidos en un

sistema MEMS o un teléfono inteligente proporcionan datos que caracterizan de mejor manera los eventos de conducción en comparación con lo obtenido por el puerto OBD.

Las categorías de eventos detectados se dividen principalmente en:

- **Velocidad.** Incluye eventos de frenar y acelerar
- **Vueltas.** Contiene eventos de vueltas a la izquierda o derecha y vueltas a la izquierda o derecha en U
- **Carril.** Incorpora eventos de cambio de carril a la izquierda o a la derecha

Se destaca una cuarta categoría propuesta por Mitrovic [3] llamada “Glorieta”, la cual incluye eventos de inicio, durante y final de la estancia en una glorieta.

El tipo de trabajo realizado por los autores puede catalogarse como:

- **Clasificación.** Se genera el modelo del clasificador y el suministro de información de la ocurrencia de un evento es aislada por un usuario. Se detectan de forma semiautomática los eventos de conducción y debido a esto se pueden obtener altas tasas de clasificación.
- **Segmentación y Clasificación.** Además de generar el modelo del clasificador, la información de la posible ocurrencia de un evento es automáticamente detectada por el mismo sistema, esto proporciona tasas de clasificación menores en comparación de trabajos que únicamente desarrollaron el modelo del clasificador.

Por lo anterior, en este trabajo se utilizan los algoritmos de aprendizaje maquina DTW y KNN debido a que se obtienen mejores tasas de clasificación en comparación de SVM, además de que podrá obtener resultados de forma más rápida debido al bajo costo computacional en comparación con HMM [3]. La implementación del sistema utiliza sensores de movimiento MEMS como plataforma de adquisición de información, ya que los datos del puerto OBD generan un menor rendimiento que el de un sensor MEMS y se descarta el uso de teléfonos inteligentes porque pueden estar equipados con diferentes tipos de sensores de movimiento y, como tal, cada uno se desempeñará de manera diferente aun teniendo el mismo algoritmo de reconocimiento. También, se propone una nueva categoría de eventos de conducción que no ha sido considerada anteriormente por otros autores, la cual denominamos “Camino” e incluye que el automóvil pase por un tope o un bache, además de retomar las categorías de eventos de conducción “Velocidad” y “Vueltas”. Como tipo de trabajo realizado se considera la de “Segmentación y Clasificación” para obtener un sistema que pueda detectar de forma automática la posible ocurrencia de un evento y posteriormente realizar la clasificación.

CAPÍTULO 2

SISTEMA AUTOMÁTICO DE CLASIFICACIÓN

En este capítulo se presenta una metodología para el desarrollo de un sistema de clasificación de eventos de conducción a partir de la aceleración, velocidad angular y ángulo de giro de dichos eventos, obtenidos mediante un sistema MEMS y con base en la teoría de Distorsión de Tiempo Dinámico (DTW) y K-Vecinos más Cercanos (KNN) como sistemas de clasificación.

El proceso de clasificación requiere, como parte esencial, la creación de modelos correspondientes a los eventos considerados como válidos. Esta tarea se basa en la hipótesis fundamental de que es posible asociar de forma biunívoca eventos de conducción de referencia con eventos de prueba. Cuando se logra satisfacer esta hipótesis en alguna implementación, se cuenta entonces con un procedimiento de asociación biunívoca. De esta manera, dada una muestra de aceleración, velocidad angular o ángulo de giro y a través del mismo procedimiento, es posible determinar si esta corresponde o no al evento de conducción que se clasifica. Es entonces necesario conformar un modelo para cada evento de conducción y establecer así un procedimiento de asociación. En las siguientes secciones se exponen los planteamientos al respecto.

2.1. METODOLOGÍA

En la figura 2.1 se muestra un esquema que plantea las metodologías utilizada en este trabajo, las cuales son implementadas de izquierda a derecha y de arriba hacia abajo. Los bloques azules muestran la conformación del clasificador y los bloques en rojo conforman el sistema. La primera metodología (bloques en azul) consiste en conformar la base de registros para un número fijo de eventos de conducción de las categorías “Velocidad”, “Vueltas” y “Camino”. A partir de esta es posible obtener los vectores de características para cada evento. Dicho conjunto de vectores permitirá definir los conjuntos de referencia y prueba, así como los modelos correspondientes. Una vez construidos los modelos de los eventos de conducción, se aplican los algoritmos DTW y KNN para clasificar los eventos y posteriormente obtener una evaluación del desempeño del clasificador.

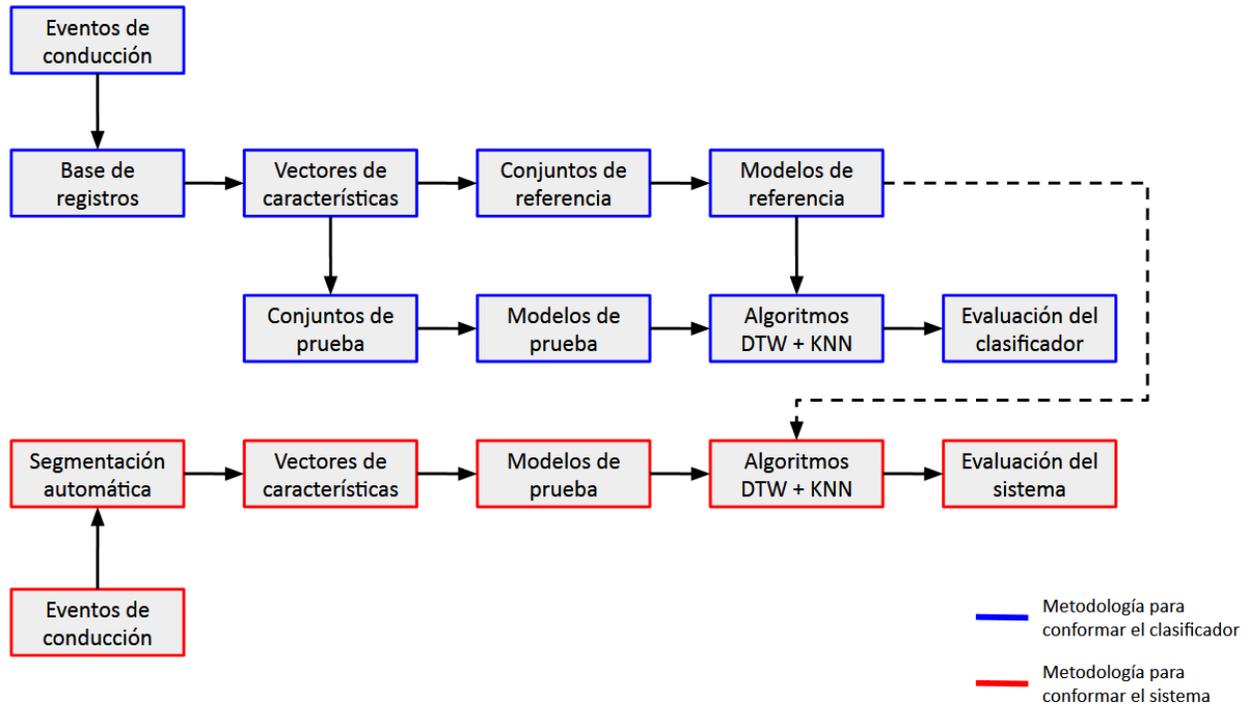


Figura 2.1: Metodología para implementar un clasificador y un sistema mediante DTW y KNN. Las flechas continuas muestran el orden de aplicación de cada etapa. La flecha punteada muestra la dependencia de los modelos de referencia al evaluar el sistema.

La metodología de los bloques en rojo tiene como fin comprobar la operación de un sistema automático de clasificación. Para ello la aceleración, velocidad angular y ángulo de giro serán sometidas a una segmentación automática, extracción de vectores de características y después ingresan a la etapa de DTW y KNN, para determinar la tasa de clasificaciones correctas de cada tipo de evento.

2.2. BASE DE REGISTROS DE EVENTOS DE CONDUCCIÓN

La creación de una base de registros de eventos de conducción tiene como principal objetivo contar con muestras representativas de aceleración, velocidad angular y ángulo de giro de cada uno de los eventos de conducción de las categorías “Velocidad”, “Vueltas” y “Camino” para así diferenciarlas de cualquier otro tipo de muestra que se considera como evento descartado.

Idealmente la creación de un sistema de verificación universal para eventos de conducción es deseable, sin embargo, actualmente no es viable por razones de implementación. De esta manera la base de registros deberá considerar tanto la variabilidad de la aceleración, velocidad angular y ángulo de giro de los eventos como la orientación o fin al que se destinará, con el objetivo de acotar sus alcances y con ello también sus características. Algunos de los aspectos específicos que pueden ser considerados para la conformación de una base de registros se enlistan a continuación:

1. **Sesiones de obtención de muestras.** A fin de considerar la variabilidad de los eventos de conducción en diferentes días, es posible realizar para cada evento, obtención de muestras en diversas sesiones en el transcurso de un día, durante una semana.
2. **Velocidad en la ejecución de un evento.** Consiste en la obtención de muestras a la velocidad usual del conductor y también a mayor y menor velocidad de la usual. La variabilidad de la aceleración, velocidad angular y ángulo de giro en la escala temporal, es una de las dificultades que se presenta en el reconocimiento de eventos de conducción. Considerar este aspecto en la obtención de muestras amplia la utilidad de las mismas y su representatividad.
3. **Condiciones del camino.** La presencia de otros conductores, las condiciones estructurales del camino y las vibraciones del automóvil al obtener muestras, no favorece el proceso de clasificación pues dificulta el procesamiento de las señales reales. Bajo esta consideración, la obtención de muestras debiera realizarse en un camino o circuito controlado y con un automóvil en perfectas condiciones mecánicas, sin ninguna otra influencia diferente a la de los eventos de conducción. Sin embargo, si el sistema será usado en un ambiente donde existen influencias externas, lo adecuado sería considerar dichos niveles de “ruido” en los registros de eventos de conducción, pues las muestras que se ingresen al sistema lo incluirán.
4. **Número de registros.** Se considera que cada evento genera un registro de conducción. El número de eventos determinará directamente la información almacenada. En teoría, dada la hipótesis de unicidad de los eventos, el incrementar el número de registros no incrementa la complejidad de la operación de un sistema de reconocimiento. En realidad, el número de registros es un factor importante para conformar un sistema confiable, ya que incrementa la probabilidad de encontrar correlación entre los registros de los eventos.
5. **Sistema de obtención de muestras.** Es posible considerar la influencia del sistema MEMS en los datos obtenidos, para ello pueden utilizarse sistemas de diferente calidad para realizar la obtención de datos simultáneos o en sesiones diferidas. Sin embargo, debido a la dificultad de compra y tiempo de transporte de estos sistemas desde el extranjero, se opta por realizar una comparación previa de las características de diferentes sistemas MEMS con base en las hojas de datos de los fabricantes, a fin de elegir el que tenga el mejor rendimiento respecto al nivel de ruido en el acelerómetro y giroscopio, facilidad de operación, opción de ángulos de clonación, entre otros. En la tabla A.1 del Anexo A se muestra una comparación entre diferentes sistemas MEMS que se consideraron para la realización de este trabajo.

6. **Variedad en la ejecución de un evento.** Este aspecto considera diferencias en la ejecución de los eventos. Si se considera que los sistemas de clasificación pueden operar reconociendo un mismo evento ejecutado de diferente forma, por ejemplo, girar el automóvil al pasar un tope o pasarlo en forma recta, deben considerarse ambos tipos de ejecución del evento.

2.2.1 PROTOCOLO DE ADQUISICIÓN DE MUESTRAS

Con base en los aspectos planteados previamente es posible establecer un protocolo de obtención de muestras, el cual permite uniformizar la adquisición de estas para cada uno de los eventos. Las tareas que integran este protocolo se describen a continuación:

- a) **Montaje del sistema MEMS.** En cada sesión de obtención de muestras se coloca el sistema suspendido rígidamente del parabrisas del automóvil y con niveles de burbuja integrados se equilibra para que la orientación de los ejes x , y del acelerómetro sean paralelos al piso y el eje z perpendicular, como se muestra en la figura 2.2. Esto se considera para tener la menor influencia de la aceleración de la gravedad en el acelerómetro y con ello no distorsionar las mediciones obtenidas de los registros de eventos de conducción. La orientación de los ejes x , y , z mencionados anteriormente tienen como supuesto que se equilibraron en una calle que no está en pendiente.

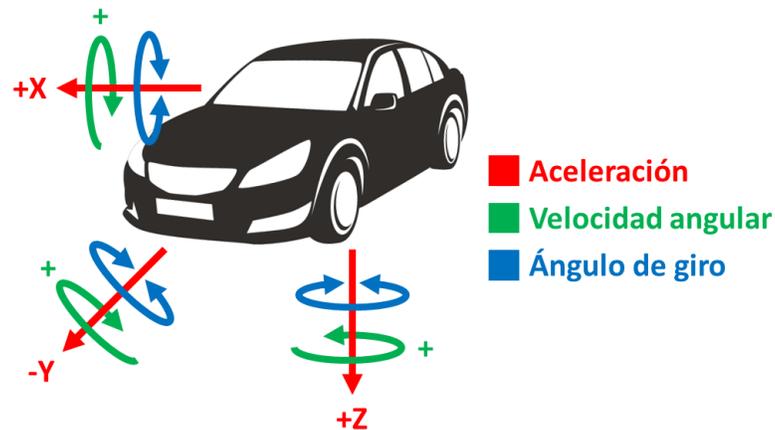


Figura 2.2: Orientación de los ejes x , y , z de la aceleración, velocidad angular y ángulo de giro respecto al automóvil. Imagen modificada de <https://www.freepik.com>

- b) **Calibración del sistema MEMS.** Esta tarea permite calibrar el acelerómetro en cada sesión de obtención de muestras. Se realiza después de colocar y equilibrar el sistema en el automóvil y mediante una aplicación en un teléfono inteligente, se envía un comando por Bluetooth al sistema MEMS para dar inicio a la rutina de calibración. Esto es importante para minimizar el efecto de cualquier *offset* que pueda tener el sistema debido a efectos de temperatura o ruido electromagnético, entre otros.
- c) **Conducción natural.** La base del protocolo de obtención de muestras es el método de conducción natural [27], en el cual el conductor maneja en la forma que normalmente lo hace, en su propio automóvil y sin ninguna instrucción específica o intervenciones. El propósito de este método es observar el comportamiento del conductor al manejar en el contexto del día a día. El valor agregado es que no se predispone a la persona a tener ciertos comportamientos al manejar un automóvil y esto refleja de mejor manera condiciones reales de conducción. Por lo cual el conductor no recibió ninguna instrucción de los eventos a realizar.
- d) **Inicio y fin de un registro.** Mediante una aplicación en un teléfono celular, una persona en el asiento del copiloto envía un comando mediante Bluetooth al sistema MEMS para indicar el inicio, fin y tipo de evento que ocurrió. Debido a que el protocolo de obtención de muestras se basa en el método de conducción natural y el conductor maneja sin ninguna instrucción específica, el copiloto debe prever la intención del conductor mediante la observación, entonces, si el conductor tiene la intención de, por ejemplo, pasar un tope, el copiloto deberá prever esa acción y antes de la ocurrencia del evento marca el inicio del registro y al finalizar marca el fin.
- e) **Registros completos.** Se consideran únicamente registros de eventos ejecutados completamente, esto quiere decir que en el transcurso de la ocurrencia de un evento de conducción no se detenga y se reanude posteriormente, por ejemplo, una persona cruce repentinamente la calle mientras se da una vuelta y se tenga que detener el automóvil o que, por condiciones densas de tránsito, una vuelta en U se ejecute en dos tiempos. Por lo tanto, los registros almacenados son de eventos ejecutados en su totalidad.

Las cinco tareas descritas previamente, conforman el protocolo de adquisición de muestras que fue usado para obtener cada uno de los registros de los eventos de conducción, los cuales generan la base de registros. Algunas de las características consideradas para la obtención de dichas muestras son las siguientes:

1. Las sesiones de obtención de muestras fueron realizadas en distintos puntos de la Ciudad de México mientras el conductor se dirigía a diferentes destinos, cabe resaltar que las calles eran conocidas y desconocidas para el conductor, con lo cual se está en conformidad con lo propuesto por el método de conducción natural.

2. Los días y horarios de obtención de muestras fueron dispersos, dependiendo de la disposición del participante.
3. El automóvil donde se realizaron los eventos de conducción fue del tipo sedán o familiar de 5 plazas, año 2017 y en condiciones mecánicas normales.
4. No se consideraron caminos de terracería o empedrados, únicamente se condujo el automóvil en trayectos de asfalto o concreto hidráulico, bajo las condiciones de las calles de la Ciudad de México.
5. El sistema MEMS utilizado para las sesiones de obtención de registros de eventos de conducción fue el JY901B, mostrado en la tabla A.1 del Anexo A. Se eligió este modelo ya que el fabricante proporcionaba información precisa de su funcionamiento, además de tener una velocidad de obtención de muestras (200 muestras por segundo) que permitió detallar de mejor manera cada uno de los eventos de conducción. El sistema embebido que guarda las muestras para su posterior tratamiento fue un Raspberry PI modelo 3B, mostrado en la tabla A.2 del Anexo A. Se eligió este sistema ya que tiene mayor soporte de bibliotecas en *lenguaje C* para acceder a los diferentes módulos de comunicación que permitían la interacción con el sistema MEMS seleccionado.

2.3. PREPROCESAMIENTO DE LAS MUESTRAS

Previo a clasificar los eventos de conducción es necesario adecuar las muestras de los rasgos característicos que definen a cada uno de los eventos. En el apartado *1.3 Estado del Conocimiento*, se observa que los autores utilizan una o varias técnicas de preprocesamiento para adecuar la información que obtuvieron, estas técnicas comúnmente son obtener estadística descriptiva, aumentar el número de muestras en las señales y filtrado mediante filtros de Respuesta Finita al Impulso (FIR). En este trabajo no se retoman las técnicas de preprocesamiento mencionadas anteriormente, ya que se desea que el sistema MEMS y el sistema embebido mencionados en el apartado 2.2.1 produzcan la clasificación de los eventos en el menor tiempo posible, entonces es necesario reducir las etapas del preprocesamiento, así como utilizar técnicas de bajo requerimiento computacional sin comprometer de sobremanera la tasa de clasificaciones correctas.

La estadística descriptiva como son valores máximos, mínimos, promedios, histogramas, entre otros, de las muestras de los rasgos característicos no es utilizada, ya que el método de clasificación con DTW y KNN emplean la información de las muestras directamente, en general, comparan la forma de una serie de muestras que representan un evento de conducción con otra serie de referencia, miden el nivel de similitud y con ello el clasificador toma una decisión. También, no es necesario aumentar el número de muestras en una serie que representa un evento por medio de

técnicas como el remuestreo, ya que el número de muestras (200 muestras por segundo) obtenidas por el sistema MEMS seleccionado proporciona la resolución suficiente para detallar cada uno de los eventos de conducción, esto verificado mediante la experimentación durante la realización de éste trabajo. Por otra parte, el uso de un filtro FIR no es considerado porque la información de los sensores esta codificada en el dominio del tiempo como una serie de tiempo y no en el dominio de la frecuencia, por lo tanto, se optó por un Filtro de Media Móvil (MAF) ya que estos tienen buen desempeño como filtro de suavizado (acción realizada en el dominio del tiempo) [28] y que por la naturaleza del clasificador con DTW y KNN, únicamente se necesita reducir el ruido de las muestras sin la necesidad de separar una banda de frecuencia de otra, como lo haría un filtro FIR.

Teniendo como base lo descrito anteriormente se procede a describir los rasgos característicos que representan a cada uno de los eventos de conducción considerados en este trabajo.

2.3.1 EXTRACCIÓN DE RASGOS CARACTERÍSTICOS

Como se mencionó en el apartado 2.3, los rasgos característicos o vectores de características de los eventos no se obtuvieron mediante valores máximos, mínimos, promedios, histogramas, entre otros, esto debido a la naturaleza del funcionamiento del clasificador con DTW y KNN que considera la medición del grado de similitud de las series de muestras. Por tal motivo fue necesario distinguir mediante la experimentación cuales muestras de aceleración, velocidad angular y ángulo de giro en los ejes x , y , z respecto al automóvil (ver figura 2.2) representan de mejor manera los eventos de conducción.

Se consideraron tres categorías donde se encuentran agrupados diferentes eventos, los cuales se muestran en la tabla 2.1.

CATEGORÍA	EVENTOS
Velocidad	Frenar y Acelerar
Vueltas	Vuelta a la izquierda o derecha y Vuelta a la izquierda o derecha en U
Camino	Tope y Bache

Tabla 2.1: Eventos de conducción que pertenecen a las diferentes categorías.

Para cada evento de conducción se obtuvieron muestras de aceleración en los ejes x , y , z , así como de velocidad angular y ángulo de giro respecto al automóvil (ver figura 2.2). En las figuras 2.3 a 2.18 se muestran ejemplos de gráficas de las magnitudes físicas que consideramos representan de mejor manera los eventos de conducción. Para una colección completa de gráficas ejemplo en los ejes x , y , z de aceleración, velocidad angular y ángulo de giro, para cada evento de conducción, ver de las figuras B.1 a B.72 del Anexo B.

Categoría: Velocidad

Evento: Frenar

Aceleración

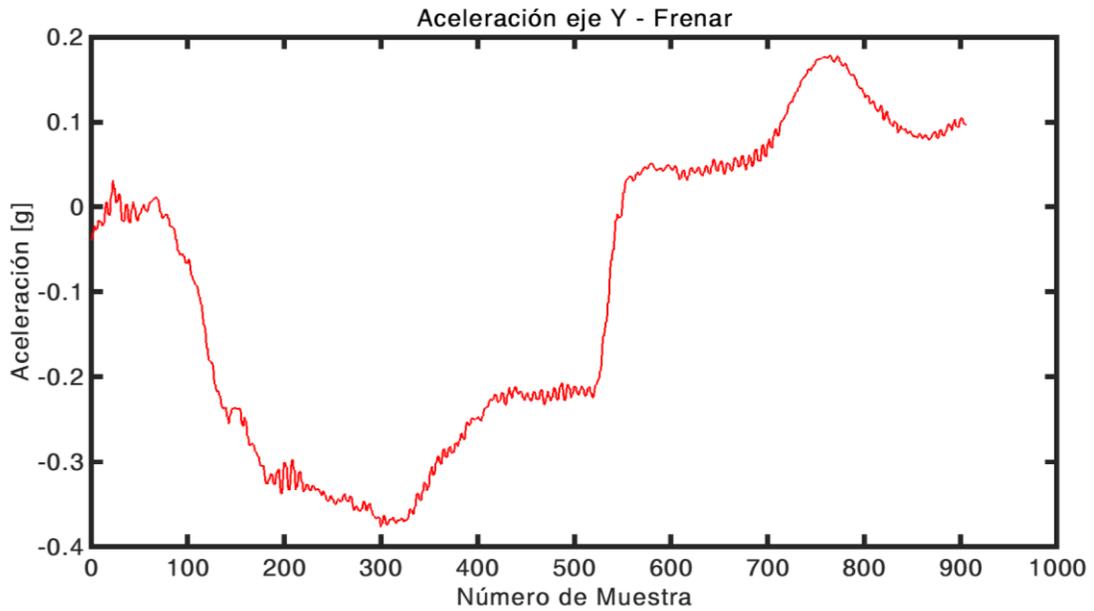


Figura 2.3: Gráfica de la aceleración en el eje y (A_y) para el evento Frenar.

Ángulo de giro

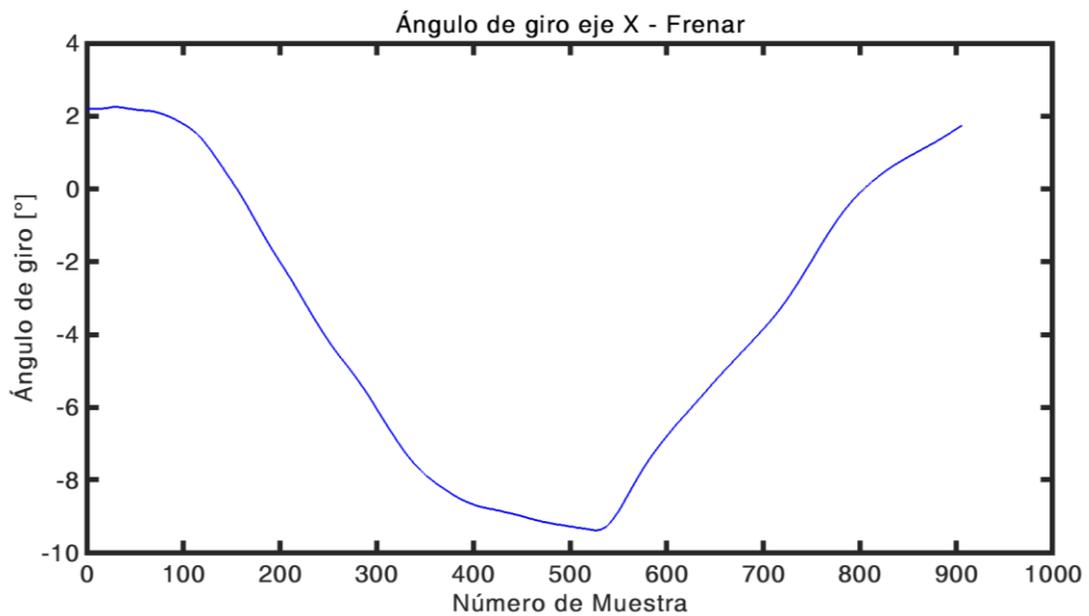


Figura 2.4: Gráfica del ángulo de giro en el eje x (E_x) para el evento Frenar, relativo a la dirección donde se detectó el inicio del evento.

Categoría: Velocidad

Evento: Acelerar

Aceleración

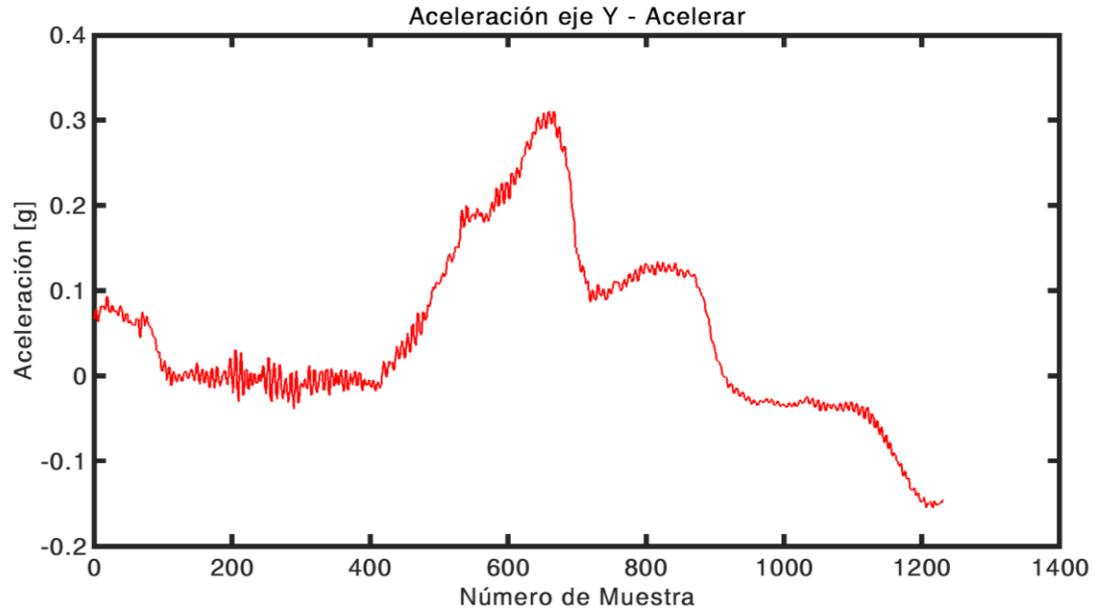


Figura 2.5: Gráfica de la aceleración en el eje y (A_y) para el evento Acelerar.

Ángulo de giro

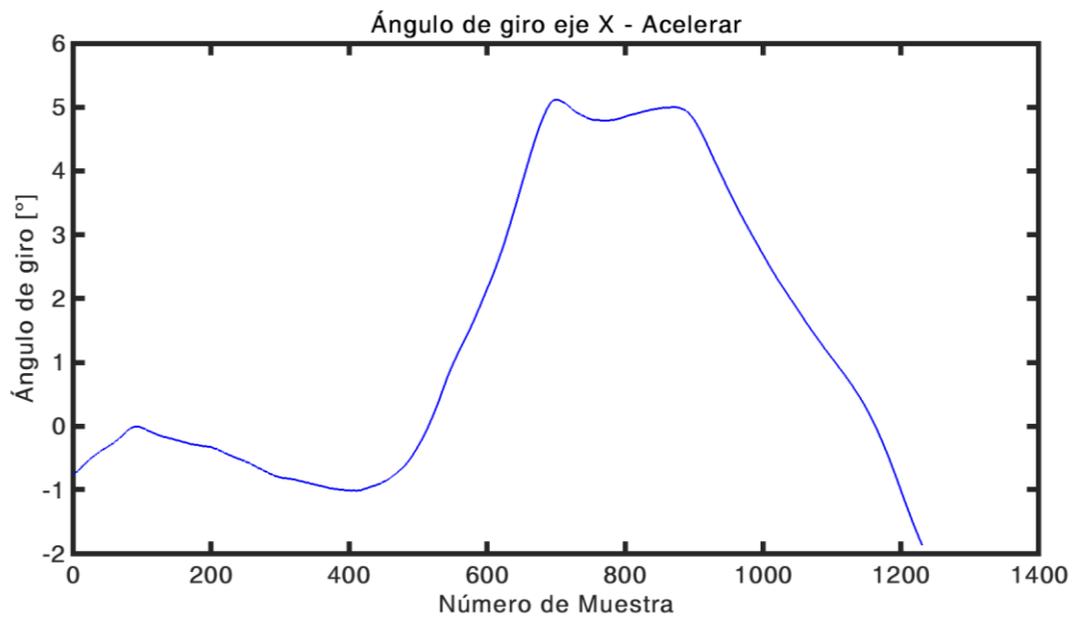


Figura 2.6: Gráfica del ángulo de giro en el eje x (E_x) para el evento Acelerar, relativo a la dirección donde se detectó el inicio del evento.

Categoría: Vueltas

Evento: Vuelta a la izquierda

Velocidad angular

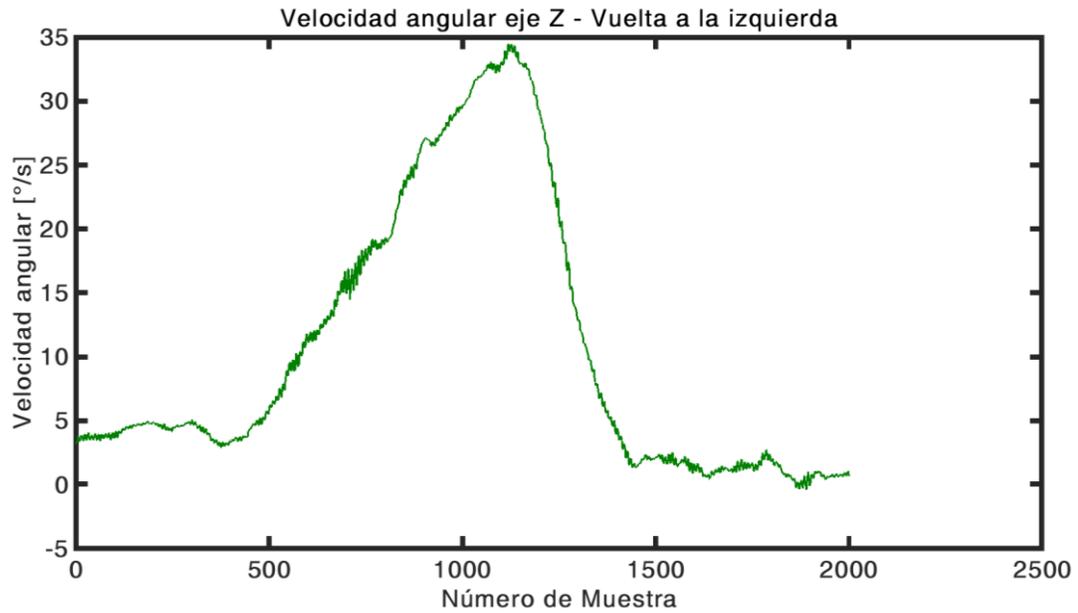


Figura 2.7: Gráfica de la velocidad angular en el eje z (G_z) para el evento Vuelta a la izquierda.

Ángulo de giro

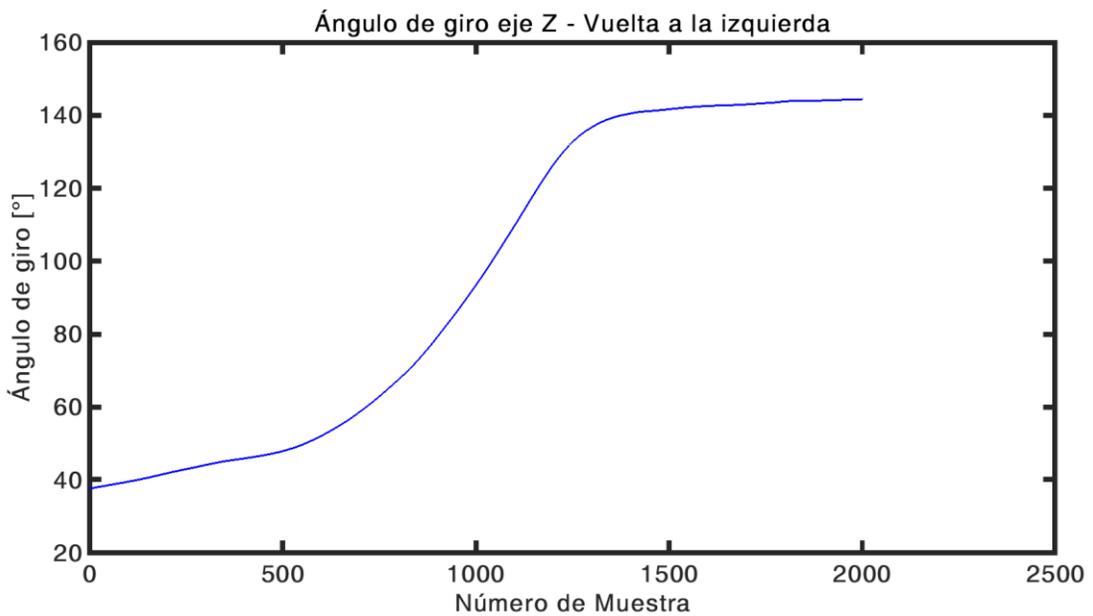


Figura 2.8: Gráfica del ángulo de giro en el eje z (E_z) para el evento Vuelta a la izquierda, relativo a la dirección donde se detectó el inicio del evento.

Categoría: Vueltas

Evento: Vuelta a la derecha

Velocidad angular

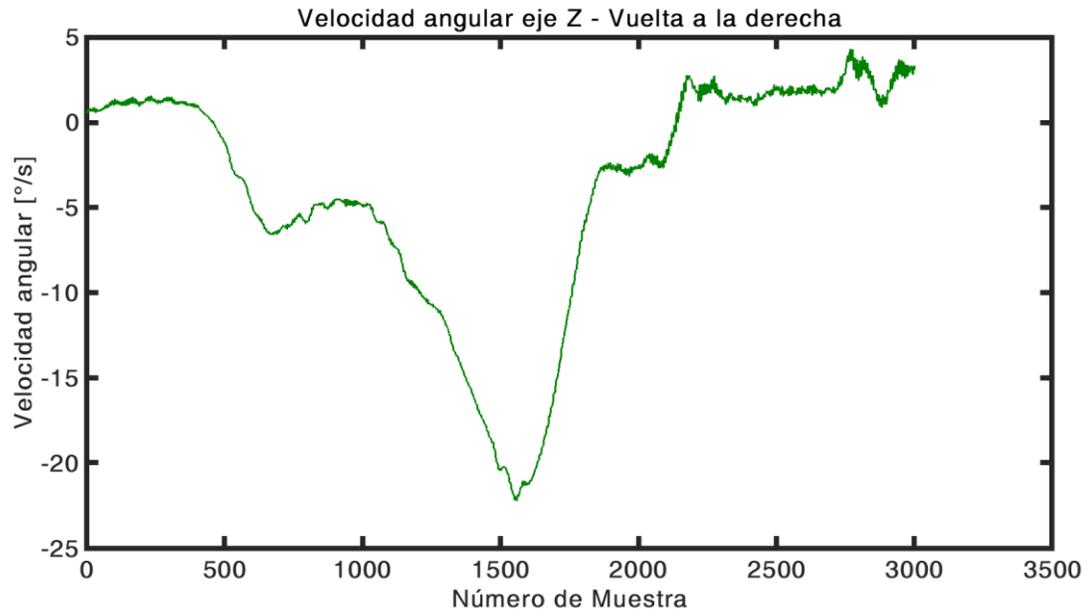


Figura 2.9: Gráfica de la velocidad angular en el eje z (G_z) para el evento Vuelta a la derecha.

Ángulo de giro

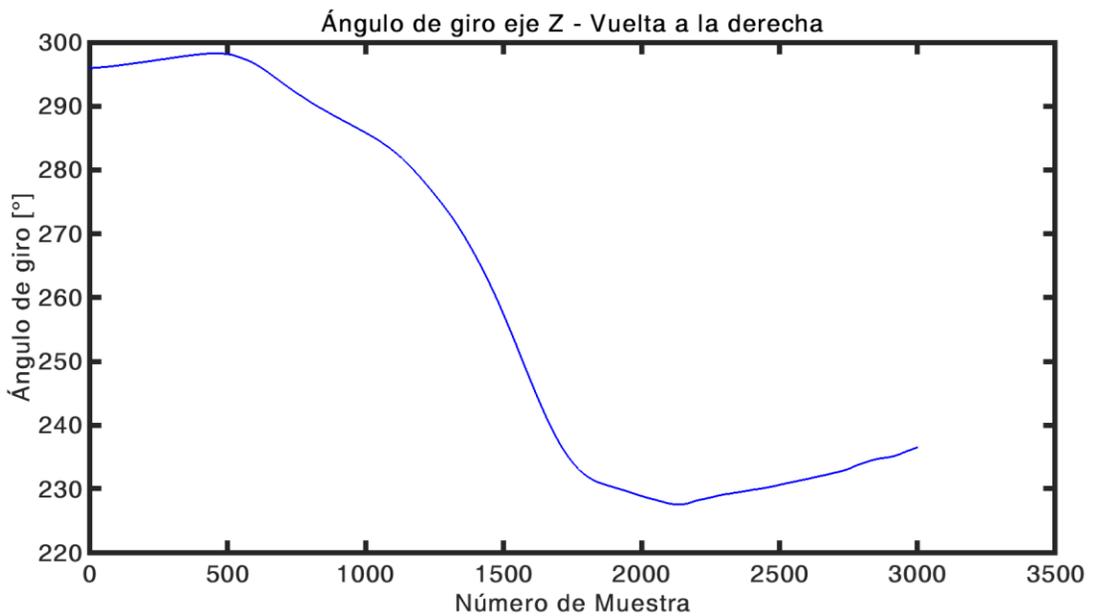


Figura 2.10: Gráfica del ángulo de giro en el eje z (E_z) para el evento Vuelta a la derecha, relativo a la dirección donde se detectó el inicio del evento.

Categoría: Vueltas

Evento: Vuelta a la izquierda en U

Velocidad angular

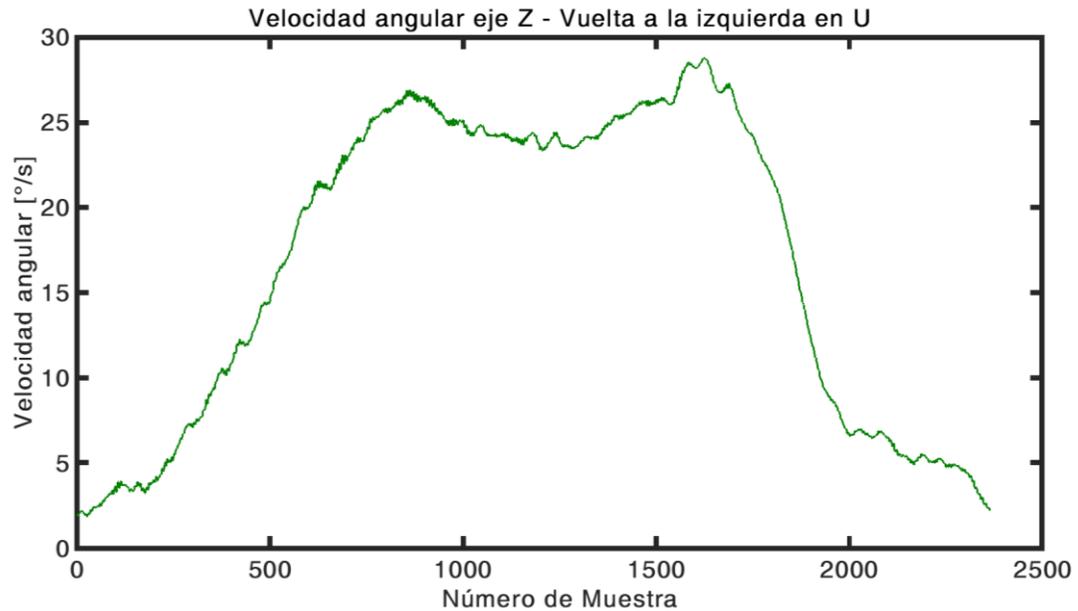


Figura 2.11: Gráfica de la velocidad angular en el eje z (G_z) para el evento Vuelta a la izquierda en U.

Ángulo de giro

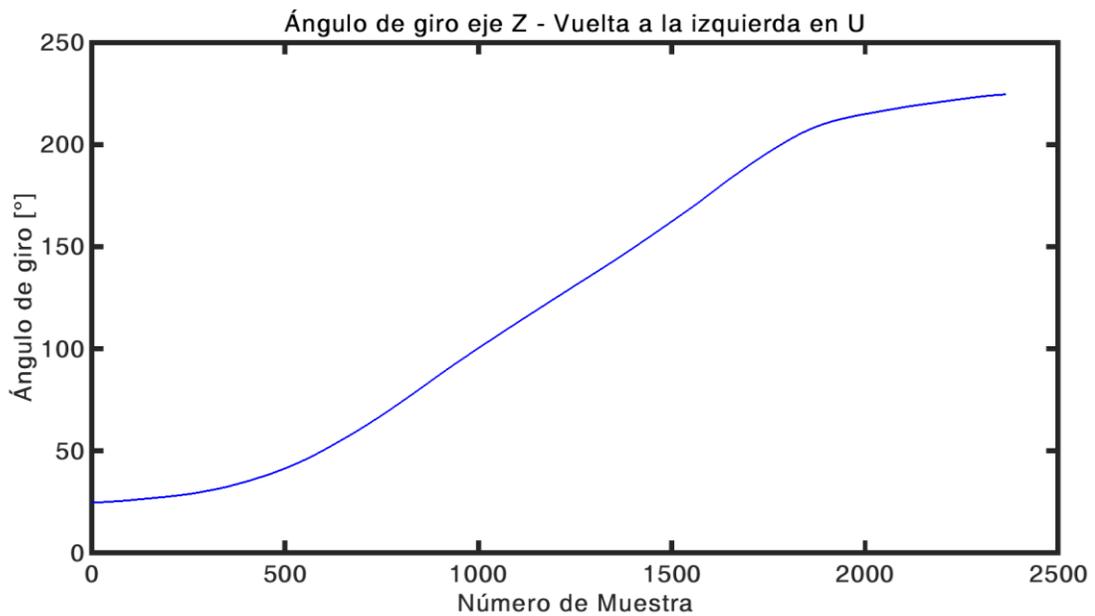


Figura 2.12: Gráfica del ángulo de giro en el eje z (E_z) para el evento Vuelta a la izquierda en U, relativo a la dirección donde se detectó el inicio del evento.

Categoría: Vueltas

Evento: Vuelta a la derecha en U

Velocidad angular

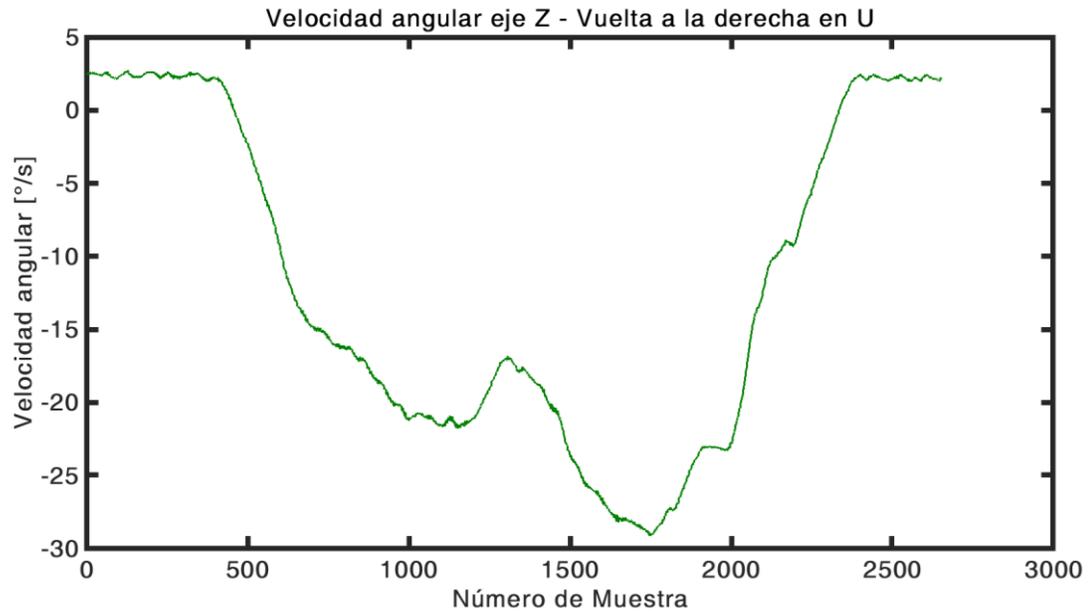


Figura 2.13: Gráfica de la velocidad angular en el eje z (G_z) para el evento Vuelta a la derecha en U.

Ángulo de giro

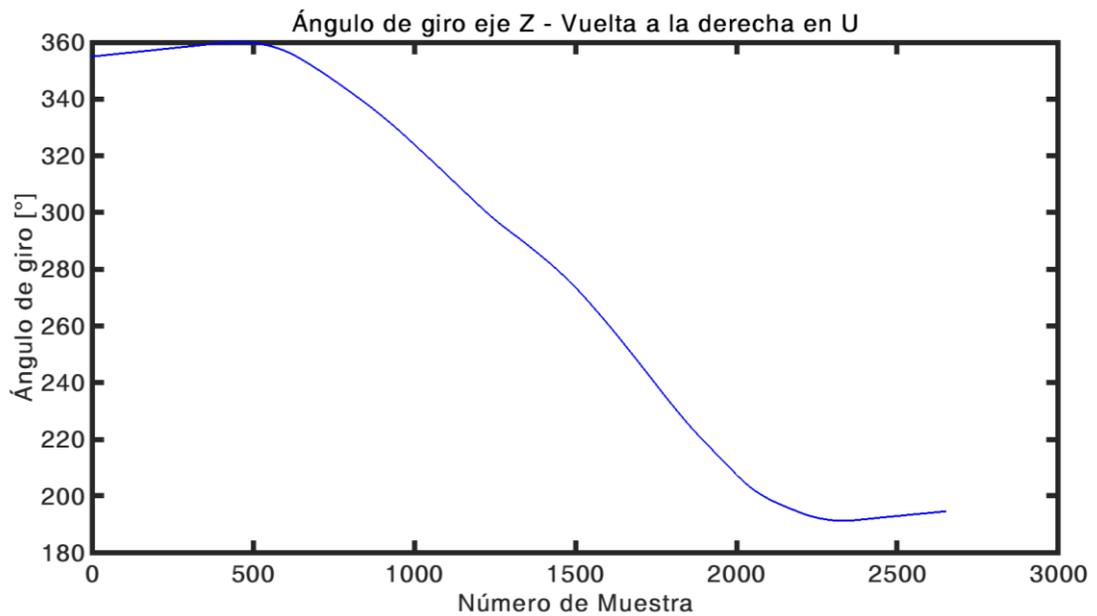


Figura 2.14: Gráfica del ángulo de giro en el eje z (E_z) para el evento Vuelta a la derecha en U, relativo a la dirección donde se detectó el inicio del evento.

Categoría: Camino

Evento: Tope

Aceleración

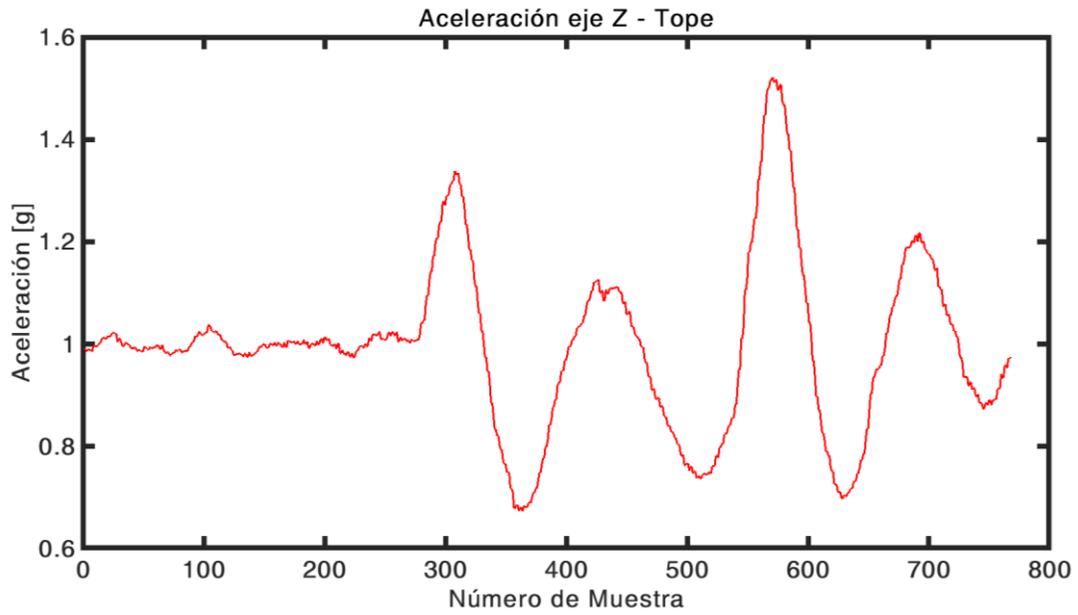


Figura 2.15: Gráfica de la aceleración en el eje z (A_z) para el evento Tope.

Velocidad angular

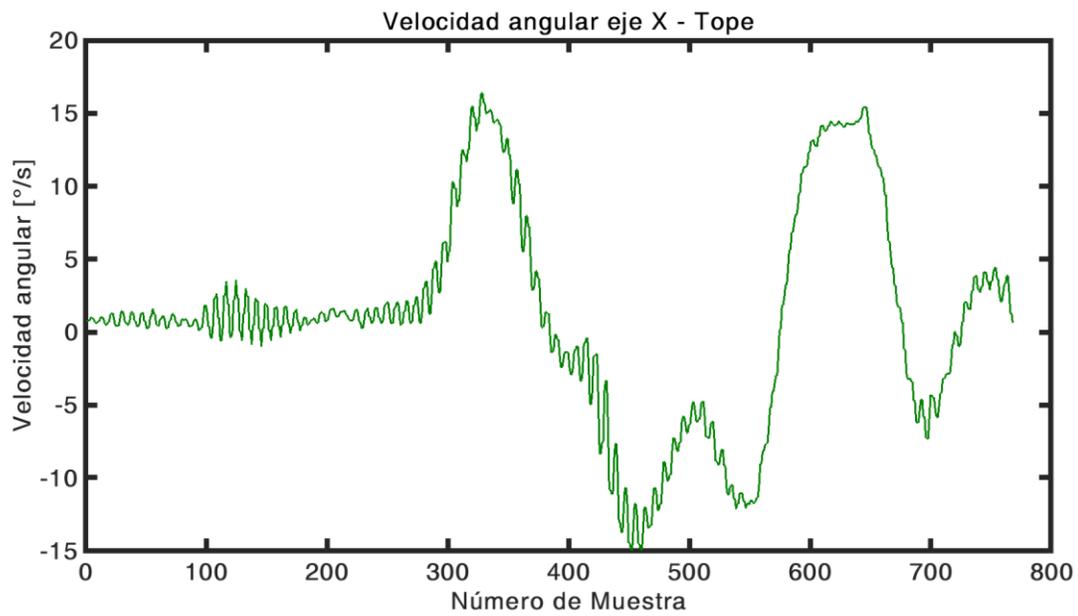


Figura 2.16: Gráfica de la velocidad angular en el eje x (G_x) para el evento Tope.

Categoría: Camino

Evento: Bache

Aceleración

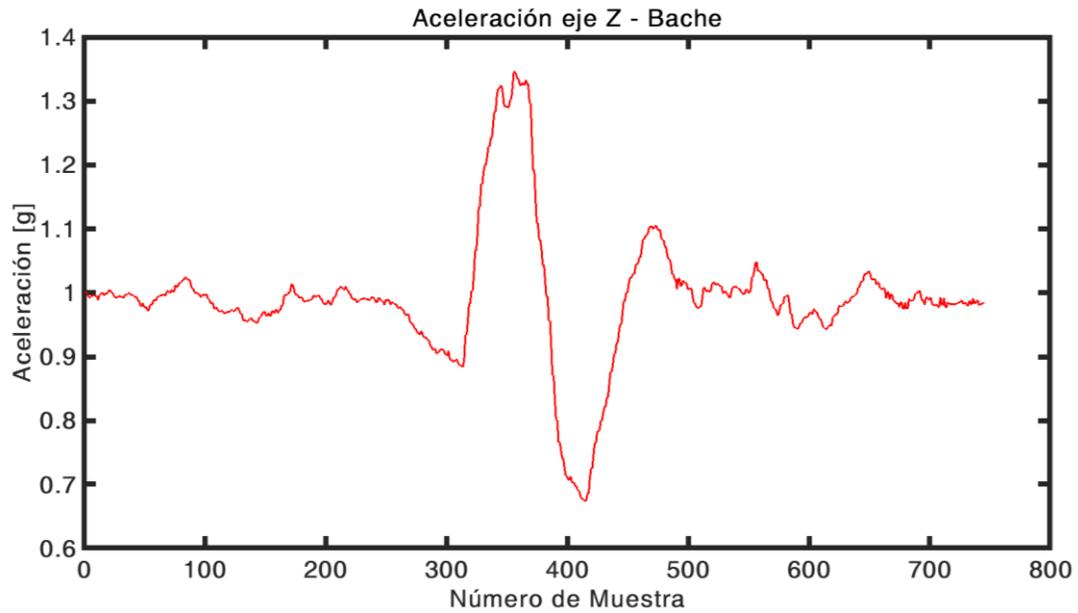


Figura 2.17: Gráfica de la aceleración en el eje z (A_z) para el evento Bache.

Velocidad angular

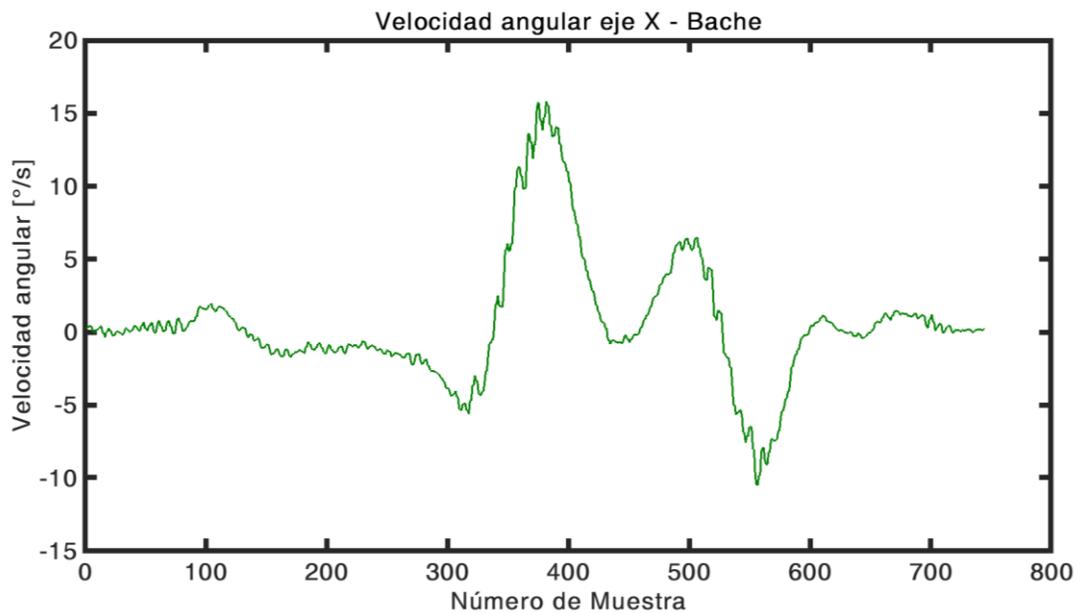


Figura 2.18: Gráfica de la velocidad angular en el eje x (G_x) para el evento Bache.

De las figuras 2.3 a 2.18, respecto a la figura 2.2 del automóvil, se tienen las tablas 2.2 a 2.4.:

Categoría: Velocidad			
Evento	Figura	Magnitud	Observación
Frenar	2.3	Aceleración eje y (A_y)	Dirección de la aceleración cuando se frena (hacia enfrente).
Frenar	2.4	Ángulo giro eje x (E_x)	El automóvil se inclina hacia enfrente.
Acelerar	2.5	Aceleración eje y (A_y)	Dirección de la aceleración cuando se acelera (hacia atrás).
Acelerar	2.6	Ángulo giro eje x (E_x)	El automóvil se inclina hacia atrás.

Tabla 2.2: Observaciones de las magnitudes que describen de mejor manera los eventos de conducción de la categoría Velocidad.

Categoría: Vueltas			
Evento	Figura	Magnitud	Observación
Vuelta a la izquierda	2.7	Velocidad angular eje z (G_z)	Velocidad y sentido de giro del automóvil (hacia la izquierda).
Vuelta a la izquierda	2.8	Ángulo de giro eje z (E_z)	Amplitud de la vuelta ($\sim 90^\circ$).
Vuelta a la derecha	2.9	Velocidad angular eje z (G_z)	Velocidad y sentido de giro del automóvil (hacia la derecha).
Vuelta a la derecha	2.10	Ángulo de giro eje z (E_z)	Amplitud de la vuelta ($\sim 90^\circ$).
Vuelta a la izquierda U	2.11	Velocidad angular eje z (G_z)	Velocidad y sentido de giro del automóvil (hacia la izquierda).
Vuelta a la izquierda U	2.12	Ángulo de giro eje z (E_z)	Amplitud de la vuelta ($\sim 180^\circ$).
Vuelta a la derecha U	2.13	Velocidad angular eje z (G_z)	Velocidad y sentido de giro del automóvil (hacia la derecha).
Vuelta a la derecha U	2.14	Ángulo de giro eje z (E_z)	Amplitud de la vuelta ($\sim 180^\circ$).

Tabla 2.3: Observaciones de las magnitudes que describen de mejor manera los eventos de conducción de la categoría Vueltas.

Categoría: Camino			
Evento	Figura	Magnitud	Observación
Tope	2.15	Aceleración eje z (A_z)	Oscilaciones del automóvil durante un tope.
Tope	2.16	Velocidad angular eje x (G_x)	Oscilaciones de velocidad del automóvil (hacia arriba y hacia abajo).
Bache	2.17	Aceleración eje z (A_z)	Una oscilación al pasar un bache.
Bache	2.18	Velocidad angular eje x (G_x)	Oscilación de velocidad del automóvil (hacia arriba y hacia abajo).

Tabla 2.4: Observaciones de las magnitudes que describen de mejor manera los eventos de conducción de la categoría Camino.

De las figuras 2.3 a 2.18 y de las tablas 2.2 a 2.4 se observa que para los eventos frenar y acelerar, los ejes que aportan información relevante para la clasificación son la aceleración en el eje y (A_y) y el ángulo de giro en el eje x (E_x) ya que consideramos describen de mejor manera el comportamiento del automóvil durante la ocurrencia de esos eventos. Para el caso de las cuatro tipos de vueltas en la categoría “Vueltas”, se observa que los ejes que aportan información relevante para la clasificación es la velocidad angular en el eje z (G_z) y el ángulo de giro en el eje z (E_z). Aunque la velocidad angular describe la velocidad con que se realiza una vuelta a la izquierda o a la derecha, no proporciona información sobre si la vuelta fue normal ($\sim 90^\circ$) o en U ($\sim 180^\circ$), por ello se auxilia de la magnitud del ángulo de giro. Por otra parte, para los eventos tope y bache, los ejes que aportan información relevante para la clasificación son la aceleración en el eje z (A_z) y la velocidad angular en el eje x (G_x), ya que representan como el automóvil oscila durante la ocurrencia de estos eventos.

Cabe resaltar que debido a la inclusión del ángulo de giro en el eje z (E_z) para conformar el vector de características de la categoría “Vueltas”, los vectores de características de las categorías “Velocidad” y “Camino” también lo incluirán, de igual manera se considera la velocidad angular en el eje z (G_z). Esto debido a que se puede realizar una primera clasificación en la cual se distingue cualquier evento de la categoría “Vueltas” con cualquier evento de las categorías “Velocidad” y “Camino”. En la sección 2.4.3 *Combinación de DTW y KNN para la Clasificación*, se describe la primera clasificación que considera la velocidad angular y el ángulo de giro.

Por lo tanto, los vectores de características serán los mismos para los eventos agrupados dentro de la misma categoría. Para el caso de “Velocidad” y “Camino” tendrán un vector primario y un vector secundario, donde el primario representa las magnitudes que propiamente representan al evento y el secundario almacena el ángulo de giro y la velocidad angular para la primera clasificación que distingue cualquier evento de la categoría “Vueltas” con cualquier evento de las categorías “Velocidad” y “Camino”. Lo anterior se muestran en la siguiente tabla.

CATEGORÍA	EVENTOS	VECTORES DE CARACTERÍSTICAS
Velocidad	Frenar y Acelerar	$S_p = [A_y, E_x]$ $S_s = [G_z, E_z]$
Vueltas	Vuelta a la izquierda o derecha y Vuelta a la izquierda o derecha en U	$T_p = [G_z, E_z]$
Camino	Tope y Bache	$R_p = [A_z, G_x]$ $R_s = [G_z, E_z]$

Tabla 2.5: Vectores de características que pertenecen a las diferentes categorías, donde: A_y = aceleración en el eje y , E_x = ángulo de giro en el eje x , G_z = velocidad angular en el eje z , E_z = ángulo de giro en el eje z , A_z = aceleración en el eje z y G_x = velocidad angular en el eje x , Los subíndices p y s indican vector primario y secundario respectivamente.

Es importante mencionar que Minglin [23] utiliza el magnetómetro de su sistema MEMS para la distinción entre vueltas y vueltas en U obteniendo buenos resultados, esto debido a que el campo magnético de la tierra que incide en los tres ejes del magnetómetro varía en magnitud y dirección de diferente manera si se realiza una vuelta normal ($\sim 90^\circ$) o en U ($\sim 180^\circ$), la desventaja de utilizar este sensor es que las mediciones se alteran en la presencia de ruido electromagnético y aunque se puede calibrar, esta sólo es válida en el punto donde se calibró y debido a que un automóvil está en constante movimiento resulta inviable. Para evitar las complicaciones al utilizar un magnetómetro, en nuestro trabajo se utilizó el ángulo de giro que proporciona nuestro sistema MEMS, el cual tiene como base la fusión de datos del acelerómetro y giroscopio para calcular los ángulos de giro o ángulos de Euler [38].

Con los criterios mencionados anteriormente para conformar los vectores de características, se construyó una base de datos de eventos de referencia, donde el número de registros por evento se muestra en la siguiente tabla:

CATEGORÍA	EVENTO	REGISTROS
Velocidad	Frenar	77
	Acelerar	70
Vueltas	Vuelta a la izquierda	78
	Vuelta a la derecha	84
	Vuelta a la izquierda en U	8
	Vuelta a la derecha en U	4
Camino	Tope	84
	Bache	86
		Total: 491

Tabla 2.6: Número de registros de vectores de características en la base de datos de referencia.

La obtención de los vectores de características de los diferentes eventos de conducción son importantes ya que se considera exclusivamente la información que mejor modela a cada evento, y con ello se puede aumentar la tasa de clasificaciones al proporcionar al clasificador únicamente de los datos más relevantes para realizar su tarea, además, en nuestro caso se reduce el espacio de almacenamiento de las muestras de los eventos de referencia, esto porque sólo se toman en cuenta cinco de las nueve magnitudes físicas que puede entregar el sistema MEMS, también con los vectores de características se reduce el tiempo de cómputo del algoritmo DTW ya que no se tendrán que comparar magnitudes que no proporcionan información relevante para el modelado de los eventos.

Posterior a la obtención de los vectores de características se reduce el ruido en esas muestras con la ayuda de un filtro MAF, el cual como se mencionó en el apartado 2.3 tiene buen desempeño como filtro de suavizado y ya que no existe la necesidad de separar una banda de frecuencias de otra se puede omitir el uso de un filtro FIR. En el siguiente apartado se describe el funcionamiento de un filtro MAF.

2.3.2 FILTRO DE MEDIA MÓVIL (MAF)

Implementación por convolución

La media móvil es el filtro más común en el procesamiento digital de señales, principalmente porque es el filtro digital más sencillo de implementar. A pesar de su simplicidad, el filtro de media móvil es óptimo para una tarea común: reducir el ruido aleatorio mientras se conserva la respuesta al paso. Esto lo convierte en el principal filtro para las señales codificadas en el dominio del tiempo. Sin embargo, el filtro de media móvil no es apto para señales codificadas en el dominio de la frecuencia, ya que cuenta con poca capacidad para separar una banda de frecuencias de otra. Filtros similares al de media móvil incluyen el filtro Gaussiano, de Blackman y media móvil de múltiples pasos. Estos tienen un rendimiento ligeramente mejor en el dominio de la frecuencia, a expensas de un mayor tiempo de cálculo [28].

Como el nombre lo indica, el filtro de media móvil opera promediando un número de puntos de la señal de entrada para producir cada punto en la señal de salida. En forma de ecuación, esto se escribe como:

$$y[i] = \frac{1}{M} \sum_{j=0}^{M-1} x[i+j] \quad (2.1)$$

Donde $x[]$ es la señal de entrada, $y[]$ es la señal de salida, y M es el número de puntos en el promedio. Por ejemplo, en un filtro de media móvil de 5 puntos, el punto 80 de la señal de salida está dado por;

$$y[80] = \frac{x[80] + x[81] + x[82] + x[83] + x[84]}{5}$$

Como una alternativa, el grupo de puntos de la señal de entrada pueden ser elegidos simétricamente alrededor del punto de salida:

$$y[80] = \frac{x[78] + x[79] + x[80] + x[81] + x[82]}{5}$$

Esto corresponde a cambiar la suma en la ecuación 2.1 de: $j = 0$ a $M - 1$, a $j = -(M - 1)/2$ a $(M - 1)/2$. Por ejemplo, en un filtro de media móvil de 11 puntos, el índice, j , puede ir de 0 a 11 (promedio de un lado) o de -5 a 5 (promedio simétrico). Promedio simétrico requiere que M sea un número impar. Programarlo es significativamente más fácil con los puntos en un solo lado; sin embargo, esto produce un desfase relativo entre la entrada y la señal de salida.

De lo anterior se reconoce que el filtro de media móvil es una convolución usando un núcleo simple. Por ejemplo, un filtro de 5 puntos tiene el núcleo: $\dots, 0, 0, 1/5, 1/5, 1/5, 1/5, 1/5, 0, 0, \dots$. Entonces el filtro de media móvil es una convolución de la señal de entrada con un pulso rectangular de área unitaria.

Respuesta en frecuencia

La figura 2.19 muestra la respuesta en frecuencia del filtro de media móvil. La cual es matemáticamente descrita por la transformada de Fourier de un pulso rectangular:

$$H[f] = \frac{\sin(\pi f M)}{M \sin(\pi f)} \quad (2.2)$$

La caída es lenta y por lo tanto la banda de atenuación es insuficiente. Claramente, el filtro de media móvil no puede separar una banda de frecuencias de otra. Un buen rendimiento en el dominio del tiempo da como resultado un bajo rendimiento en el dominio de la frecuencia, y viceversa. En resumen, la media móvil es un buen filtro de suavizado (acción en el dominio del tiempo), pero de bajo rendimiento como filtro paso bajo (acción en el dominio de la frecuencia).

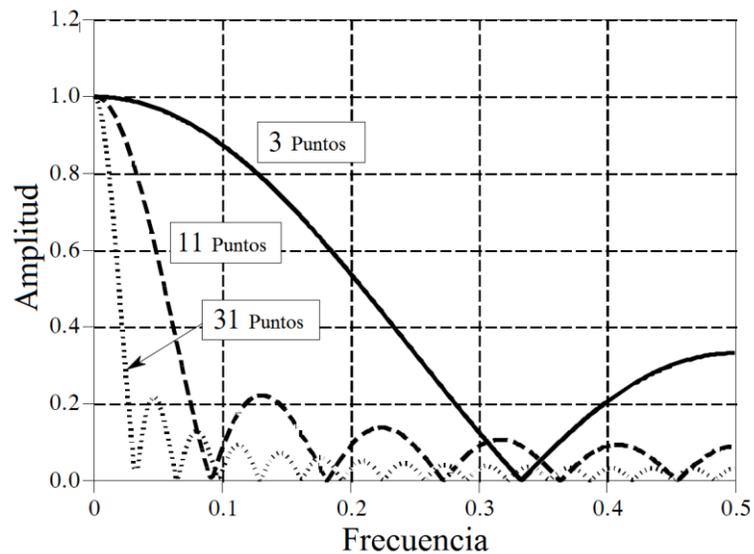


Figura 2.19: Respuesta en frecuencia del filtro de media móvil. La media móvil tiene bajo rendimiento como filtro paso bajo, debido a su caída lenta y a la insuficiente banda de atenuación [28].

Implementación recursiva

Una ventaja del filtro de media móvil es que puede ser implementado con un algoritmo recursivo. Por ejemplo, se ingresa una señal de entrada $x[]$, a través de un filtro de media móvil de 7 puntos para generar una señal de salida, $y[]$. Se calculan dos puntos adyacentes, $y[50]$ y $y[51]$:

$$y[50] = x[47] + x[48] + x[49] + x[50] + x[51] + x[52] + x[53]$$

$$y[51] = x[48] + x[49] + x[50] + x[51] + x[52] + x[53] + x[54]$$

Se observa que son cálculos semejantes; los puntos $x[48]$ hasta $x[53]$ deben ser sumados para $y[50]$, y de nuevo para $y[51]$. Si $y[50]$ ha sido calculado anteriormente, una forma eficiente de calcular $y[51]$ es:

$$y[51] = y[50] + x[54] - x[47]$$

Una vez que se ha calculado $y[51]$ utilizando $y[50]$, entonces $y[52]$ se obtiene de la muestra $y[51]$, y así sucesivamente. Después de que el primer punto es calculado en $y[]$, los puntos restantes pueden obtenerse con sólo una adición y una sustracción por punto. Esto se expresa en la siguiente ecuación:

$$y[i] = y[i - 1] + x[i + p] - x[i - q] \quad (2.3)$$

$$p = (M - 1)/2$$

$$q = p + 1$$

Se observa que la ecuación 2.3 utiliza dos fuentes de datos para calcular cada punto en la salida: puntos de la entrada y puntos previamente calculados de la salida. Por lo cual es una ecuación del tipo recursiva, lo que quiere decir que el resultado de un cálculo es utilizado en cálculos posteriores.

El algoritmo del filtro de media móvil es más rápido a comparación de otros filtros digitales como los de Respuesta Infinita al Impulso (IIR) o los de Respuesta Finita al Impulso (FIR). Primero, sólo existen dos cálculos por punto, sin importar la longitud del núcleo del filtro. Segundo, adición y sustracción son las operaciones matemáticas más recurrentes, mientras que la mayoría de filtros digitales utilizan diversas multiplicaciones que requieren mayor tiempo de cómputo. Tercero, el esquema de los índices es simple. Cada índice p y q de la ecuación 2.3 se encuentra mediante adición o sustracción de constantes enteras que pueden calcularse antes de que el procedimiento de filtrado inicie. Cuarto, el algoritmo puede ser llevado a cabo con representación de número enteros. Dependiendo del *hardware* utilizado, el cálculo con números enteros puede ser más rápido que con números de punto flotante por más de un orden de magnitud.

2.4. ALGORITMOS DE CLASIFICACIÓN

Una vez conformada la base de registros de vectores de características que representan los diferentes eventos de conducción, se necesita elegir un método de clasificación que permita catalogar dichos eventos. En el apartado *1.3 Estado del Conocimiento*, se observa que los autores utilizan diferentes técnicas, principalmente algoritmos de aprendizaje maquina como Máquinas de Soporte Vectorial (SVM), Modelos Ocultos de Markov (HMM), K-Means y la combinación de los algoritmos Distorsión de Tiempo Dinámico (DTW) y K-Vecinos más Cercanos (KNN) (ver tabla 1.1). En general estos algoritmos funcionan de la siguiente manera para la clasificación de eventos de conducción:

- a) **Máquinas de Soporte Vectorial (SVM).** Dado un conjunto de puntos en el que cada uno de ellos pertenece a una de diferentes clases, se construye un modelo capaz de estimar si un nuevo punto pertenece a una clase o a otra. La SVM busca el modelo de un hiperplano o conjunto de hiperplanos en un espacio de dimensionalidad muy alta que separe de forma óptima a los puntos de una clase de otra. Para generar los puntos que necesita la SVM que clasifica eventos de conducción, normalmente se utilizan valores máximos, mínimos, promedios, histogramas, entre otros de los vectores de características. Con esto se genera un segundo vector de alta dimensionalidad el cual puede ser catalogado por la SVM [23].
- b) **Modelos Ocultos de Markov (HMM).** Son modelos estadísticos en el que se asume que el sistema a modelar es un proceso aleatorio dependiente del tiempo. El objetivo es determinar los parámetros desconocidos u ocultos de una cadena de estados a partir de los parámetros observables. Para generar la cadena o modelos que clasifica eventos de conducción, normalmente se elige el número de estados con base en los diferentes cambios repentinos de las series de muestras de los vectores de características. Los parámetros desconocidos son la probabilidad de transición de un estado a otro con base en un análisis probabilístico de los vectores de características y los parámetros observables son propiamente los vectores de características [3].
- c) **K-Means.** Es un método de agrupamiento que tiene como objetivo la partición de un conjunto de n observaciones en K grupos, en el que cada observación pertenece al grupo cuyo valor medio es más cercano. Al igual que las SVM, para generar las observaciones, normalmente se utilizan valores máximos, mínimos, promedios, histogramas, entre otros de los vectores de características de los eventos de conducción [12].

En este trabajo se retoma la combinación de los algoritmos DTW y KNN ya que su funcionamiento emplea directamente la información de las series de datos de los vectores de características, por lo que no es necesario obtener estadística descriptiva como en el caso de SVM y K-Means, en general, DTW compara una serie de datos de un vector de características que representan cualquier evento

de conducción contra diferentes vector de prueba, miden el nivel de similitud y con ello KNN toma la decisión de la mejor correspondencia. También, no es necesario determinar el número de estados o un análisis probabilístico como en el caso de HMM. Otro aspecto que refuerza el uso de DTW y KNN es que la forma de las gráficas de las magnitudes físicas de los vectores de características, mostradas en el apartado 2.3.1 *Extracción De Rasgos Característicos*, en su mayoría se diferencian entre sí y debido a que DTW compara dos series de muestras, hay menor probabilidad de que exista una clasificación incorrecta, además ambos algoritmos no necesitan propiamente una etapa de entrenamiento como SVM, HMM y K-Means y la combinación de DTW y KNN tiene altas tasas de clasificación para catalogar diversos eventos de conducción, como se muestra en la tabla 1.1.

Teniendo como base lo descrito anteriormente se procede a describir el funcionamiento de los algoritmos DTW y KNN.

2.4.1. DISTORSIÓN DE TIEMPO DINÁMICO (DTW)

Una tarea común con los datos de series de tiempo es comparar una secuencia con otra. En algunos dominios una medida de distancia simple, como la distancia Euclidiana será suficiente. Sin embargo, a menudo ocurre que dos secuencias tienen aproximadamente las mismas formas de componentes generales, pero estas formas no se alinean en el tiempo. La figura 2.20 muestra esto con un ejemplo. Para encontrar la similitud entre tales secuencias, o como un paso de preprocesamiento antes de promediarlas, debemos "distorsionar" el eje del tiempo de una (o ambas) secuencias para lograr una mejor alineación. Distorsión de Tiempo Dinámico (DTW) es una técnica para lograr de manera eficiente esta distorsión [29].

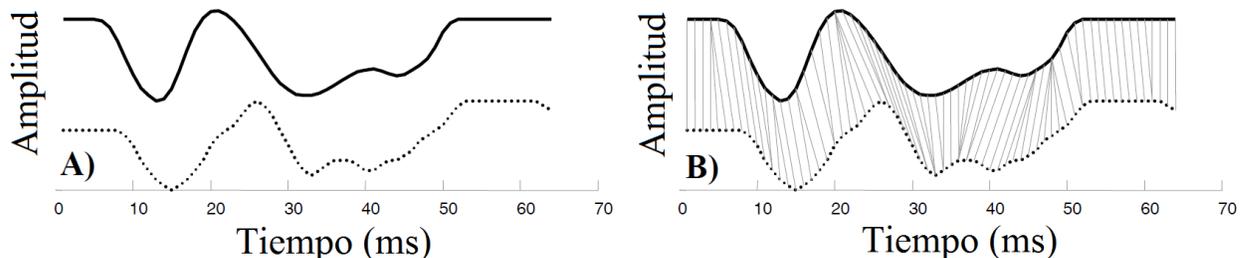


Figura 2.20: Un ejemplo de la utilidad de la distorsión de tiempo dinámico. A) Dos secuencias que, si bien tienen una forma general similar, no están alineadas en el eje del tiempo. Una medida de distancia que asume que el i -ésimo punto en una secuencia está alineado con el i -ésimo punto en la otra producirá una desemejanza. B) DTW puede encontrar una alineación entre las dos secuencias que permita calcular una medida de distancia o similitud más sofisticada. [29].

En el análisis de series de tiempo, DTW es un algoritmo que encuentra para cada muestra en una de las secuencias, la correspondiente muestra en la otra secuencia que es lo más cercana a la muestra original, usando algunas métricas predefinidas. Dada esta correspondencia, es posible calcular la "distancia" entre las secuencias bajo comparación para medir la similitud entre ellas [33].

El algoritmo DTW fue originalmente diseñado por Sakoe y Chiba [30] como una técnica para el reconocimiento del habla y algunas de las aplicaciones adicionales que se le ha dado a este algoritmo es el reconocimiento de rostros [31], clasificación de vehículos [32] y la verificación de firmas [33]. En este trabajo extendemos su uso para la clasificación de eventos de conducción.

El algoritmo de distorsión de tiempo dinámico

Supóngase que se tienen dos series de tiempo Q y C , de longitud n y m respectivamente, donde:

$$Q = q_1, q_2, \dots, q_i, \dots, q_n \quad (2.4)$$

$$C = c_1, c_2, \dots, c_j, \dots, c_m \quad (2.5)$$

Para alinear dos secuencias usando DTW se construye una matriz de $n \times m$ donde el (i -ésimo, j -ésimo) elemento de la matriz contiene la distancia $d(q_i, c_j)$ entre los puntos q_i y c_j (típicamente se utiliza la distancia Euclidiana, por lo tanto $d(q_i, c_j) = \sqrt{(q_i - c_j)^2}$). Cada elemento (i, j) de la matriz corresponde a la alineación entre los puntos q_i y c_j . Esto se ilustra en la figura 2.21. Un camino distorsionado W , es un conjunto contiguo de elementos de la matriz que define un mapeo entre Q y C . El k -ésimo elemento de W está definido como $w_k = (i, j)_k$, entonces se tiene:

$$W = w_1, w_2, \dots, w_k, \dots, w_K \quad (2.6)$$

$$\max(m, n) \leq K \leq m + n - 1$$

El camino distorsionado está típicamente sujeto a diferentes restricciones:

- **Condiciones de frontera:** $w_1 = (1, 1)$ y $w_K = (m, n)$, simplemente indicado, esto requiere que el camino de deformación comience y termine en celdas de la esquina de la matriz diagonalmente opuestas.
- **Continuidad:** Dado $w_k = (a, b)$ entonces $w_{k-1} = (a', b')$ donde $a - a' \leq 1$ y $b - b' \leq 1$. Esto restringe los pasos permitidos en el camino de deformación a celdas adyacentes (incluidas celdas diagonalmente adyacentes).
- **Monotonidad:** Dado $w_k = (a, b)$ entonces $w_{k-1} = (a', b')$ donde $a - a' \geq 0$ y $b - b' \geq 0$. Esto obliga a los puntos en W a estar monótonamente espaciados en tiempo.

Existen diversos caminos de deformación que satisfacen las condiciones anteriores, sin embargo, sólo se interesa por el camino que minimiza el costo de la deformación:

$$DTW(Q, C) = \min \left\{ \frac{\sqrt{\sum_{k=1}^K w_k}}{K} \right\} \quad (2.7)$$

La letra K en el denominador de la ecuación anterior se usa para compensar el hecho de que los caminos de deformación pueden tener diferentes longitudes.

El camino que minimiza el costo de la deformación puede encontrarse eficientemente utilizando programación dinámica para evaluar la siguiente recurrencia que define la distancia acumulada $\gamma(i, j)$ como la distancia $d(i, j)$ encontrada en la celda actual y el mínimo de las distancias acumuladas de los elementos adyacentes:

$$\gamma(i, j) = d(q_i, c_j) + \min\{\gamma(i-1, j-1), \gamma(i-1, j), \gamma(i, j-1)\} \quad (2.8)$$

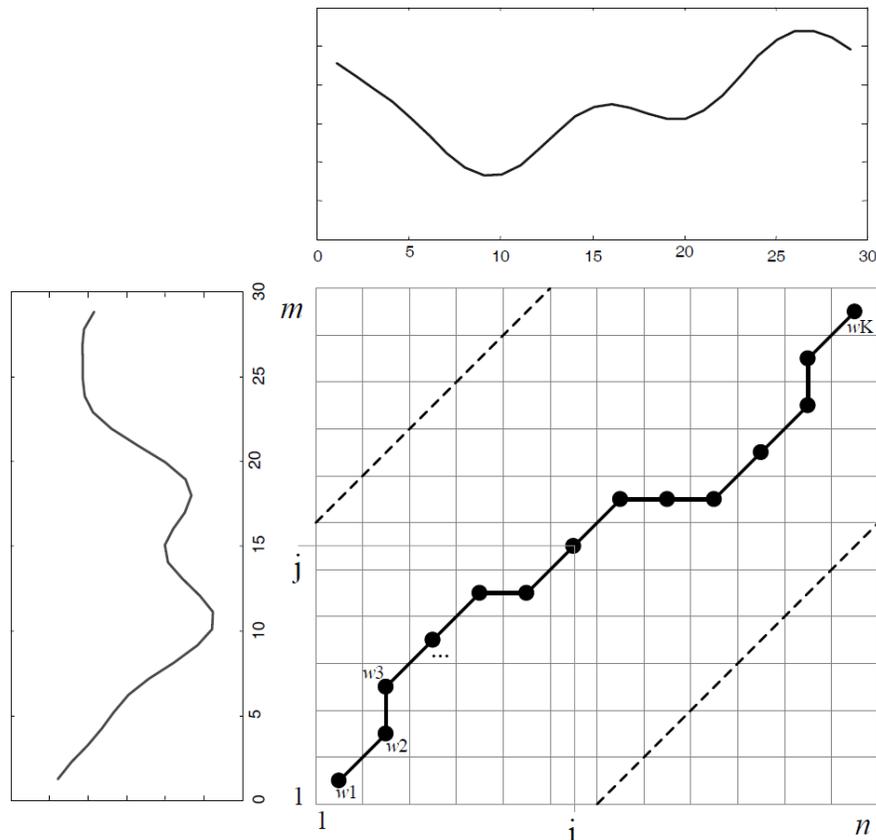


Figura 2.21: Ejemplo de una matriz de distancias y su respectivo camino deformado [29].

Restringiendo el algoritmo de distorsión de tiempo dinámico

Aunque DTW se ha utilizado con éxito en muchos dominios, puede producir resultados patológicos. La observación crucial es que el algoritmo puede tratar de explicar la variabilidad en el eje y al deformar el eje x . Esto puede conducir a alineamientos poco intuitivos donde un solo punto en una serie de tiempo se correlaciona con una gran subsección de otra serie temporal. A los ejemplos de este comportamiento indeseable se le llaman "singularidades". Se ha propuesto una variedad de medidas para tratar las singularidades. Todos estos enfoques limitan esencialmente las posibles deformaciones permitidas.

El problema de las singularidades se observó por Sakoe y Chiba [30]. Varios métodos que se han propuesto para corregir el problema se describen a continuación:

- 1) **Ventana:** Los elementos permitidos de la matriz se pueden restringir a aquellos que caen en una ventana de distorsión, $|i - (n/(m/j))| < R$, donde R es un entero positivo ancho de ventana. Esto significa que las esquinas de la matriz no se consideran, como lo muestran las líneas punteadas en la figura 2.21.
- 2) **Ponderaciones de pendiente:** Si la ecuación 2.8 es remplazada con $\gamma(i, j) = d(i, j) + \min\{\gamma(i - 1, j - 1), X\gamma(i - 1, j), X\gamma(i, j - 1)\}$ donde X es un número real positivo, se puede restringir la distorsión al cambiar el valor de X . A medida que X aumenta, el camino de distorsión se inclina cada vez más hacia la diagonal.
- 3) **Patrones de pasos (restricciones de pendiente):** Se puede visualizar la ecuación 2.8 como un diagrama de patrones de paso admisibles, como en la figura 2.22A. Las flechas muestran los pasos permitidos que el camino de distorsión puede tomar en cada etapa. Se puede remplazar la ecuación 2.8 con $\gamma(i, j) = d(i, j) + \min\{\gamma(i - 1, j - 1), \gamma(i - 1, j - 2), X\gamma(i - 2, j - 1)\}$, que corresponde con el patrón de pasos mostrado en la figura 2.22B. Usando esta ecuación, el camino de distorsión es obligado a moverse en diagonal para cada paso paralelo a un eje.

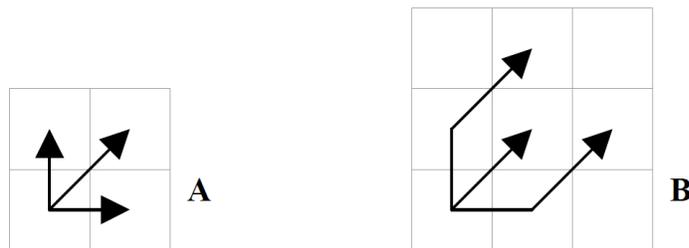


Figura 2.22: Representación pictográfica de dos alternativas de patrones de paso [29]:

A) Patrón correspondiente a $\gamma(i, j) = d(i, j) + \min\{\gamma(i - 1, j - 1), \gamma(i - 1, j), \gamma(i, j - 1)\}$

B) Patrón correspondiente a $\gamma(i, j) = d(i, j) + \min\{\gamma(i - 1, j - 1), \gamma(i - 1, j - 2), \gamma(i - 2, j - 1)\}$

2.4.2. K-VECINOS MÁS CERCANOS (KNN)

La clasificación se considera como uno de los componentes importantes de los sistemas inteligentes. En las diferentes técnicas de clasificación, se tiene una variable especial de valores discretos, llamada clase y el objetivo es estimar a qué clase pertenece un objeto. K-Vecinos más Cercanos (KNN) es uno de los algoritmos más simple y conocido para realizar esta tarea. Este algoritmo se ha utilizado en varias aplicaciones, como el procesamiento de imágenes [35] y el reconocimiento de escritura a mano [36]. KNN es un algoritmo basado en memoria que no requiere un entrenamiento o modelo explícito y, por lo tanto, también es conocido como algoritmo de “aprendizaje perezoso”, al contrario de un “aprendizaje entusiasta” donde se realiza un entrenamiento antes de realizar la clasificación. El algoritmo proporciona la estimación de máxima similitud de la clase [34].

El algoritmo de clasificación KNN encuentra un grupo cercano de K objetos en el conjunto de datos de entrenamiento y estima la clase del objeto a clasificar con base en los objetos de entrenamiento más cercanos. Tres elementos clave involucrados en el algoritmo son:

- a) El conjunto de objetos almacenados (datos de entrenamiento)
- b) Una distancia o medición similar
- c) Un apropiado valor de K

La medida de distancia utilizada comúnmente con KNN es la Euclidiana. Sin embargo, otra medida de distancia como Manhattan, Hamming o Minkowski también son usadas. Este algoritmo proporciona resultados satisfactorios cuando se aplica en bases de datos que tienen valores determinados o definidos, pero no es capaz de manejar bases de datos inciertas.

El algoritmo de vecinos más cercanos (NNR)

Dado un conjunto de N pares $(x_1, \theta_1), (x_2, \theta_2), \dots, (x_N, \theta_N)$, donde las x_i obtienen valores de un espacio de medición X sobre el cual se define la medición d , y las θ_i toman valores de un conjunto finito $\{\omega_1, \omega_2, \dots, \omega_M\}$. Cada θ_i se considerada el índice de la categoría a la que pertenece i -ésimo individuo, y cada x_i es el resultado del conjunto de atributos de ese individuo. Para abreviar, con frecuencia se menciona que “ x_i pertenece a θ_i ”.

Dado un nuevo par (x, θ) , donde sólo los atributos de x son conocidos, y se desea estimar θ utilizando la información contenida en el conjunto de puntos clasificados correctamente. Se denomina:

$$x_{NN} \in \{x_1, x_2, \dots, x_N\} \quad (2.9)$$

un vecino más cercano a x si:

$$\min_{i = 1, 2, \dots, N} \{d(x_i, x)\} = d(x_{NN}, x) \quad (2.10)$$

El algoritmo de vecinos más cercano decide que x pertenece a la categoría θ_{NN} de su vecino más cercano x_{NN} . En caso de empate entre vecinos, el algoritmo puede ser modificado para decidir la categoría más común entre quienes empataron.

El algoritmo de votación KNN es una extensión del algoritmo NNR. KNN utiliza la información de los K vecinos más cercanos del patrón sin clasificar para realizar una decisión.

El algoritmo de K-vecinos más cercanos (KNN)

Un individuo sin clasificar es asignado a la clase representada por la mayoría de sus K vecinos más cercanos. En el algoritmo, se asume que los K vecinos tienen igual peso en la decisión sin importar la distancia con el individuo x a ser clasificado. Es intuitivo apelar a dar diferentes pesos a los K vecinos en función de sus distancias a x , dando un peso mayor a los vecinos más cercanos.

Sea d la distancia medida, y x_1, x_2, \dots, x_K los K vecinos más cercanos a x ordenados en orden ascendente respecto a $d(x_i, x)$. Donde x_1 es el primer vecino más cercano a x . Dudani [37] propone asignar al i -ésimo vecino más cercano x_i , un peso w_i definido como:

$$w_i = \begin{cases} \frac{d(x_K, x) - d(x_i, x)}{d(x_K, x) - d(x_1, x)} & \text{si } d(x_K, x) \neq d(x_1, x) \\ 1 & \text{si } d(x_K, x) = d(x_1, x) \end{cases} \quad (2.11)$$

El individuo x se asigna a la clase para la cual los pesos de los representantes entre los K vecinos más cercanos suman el mayor valor. Esta regla ha sido mostrada por Dudani que produce tasas de error más bajas que las obtenidas usando únicamente KNN.

2.4.3. COMBINACIÓN DE DTW Y KNN PARA LA CLASIFICACIÓN

Suponiendo un clasificador de eventos de conducción con base únicamente en DTW y vectores de características de referencia y prueba de una dimensión (una sólo serie de datos en el eje de alguna magnitud de aceleración, velocidad angular o ángulo de giro), asignará el tipo de evento correspondiente a la menor medición de distancia entre las secuencias bajo comparación. El problema de esta aproximación es que pueden existir diferentes distancias mínimas con el mismo valor, correspondientes a diferentes tipos de eventos y el clasificador puede elegir la primera ocurrencia o una al azar, lo cual resulta en una baja tasa de clasificaciones. Además, al tener vectores de características de una dimensión, no existe suficiente información para representar y diferenciar los eventos de conducción.

Ahora, suponga un clasificador con base en la combinación de DTW-KNN y vectores de características de referencia y prueba de una dimensión (una sólo serie de datos en el eje de alguna magnitud de aceleración, velocidad angular o ángulo de giro). El algoritmo KNN realiza una votación entre las K menores mediciones de distancia proporcionadas por el algoritmo DTW, de los eventos de referencia contra el evento de prueba para asignar la clase o tipo de evento del que se trata. Si se considera $K = 1$ se tiene el caso del párrafo anterior, pueden existir diferentes distancias mínimas con el mismo valor, correspondientes a diferentes tipos de eventos y el clasificador elegirá la primera ocurrencia; KNN se convierte en NNR. El problema puede resolverse variando entre 2 y N el número de vecinos K en la votación, donde N es el número máximo de vectores de características de referencia. De esta forma se reduce la probabilidad de que exista un empate y se aumenta la tasa de clasificaciones, esto se aprecia de mejor manera en el apartado *3.3.1 Pruebas y Resultados*.

La situación descrita en el párrafo anterior considera que se tienen vectores de características de referencia y prueba de una dimensión (una sólo serie de datos en el eje de alguna magnitud de aceleración, velocidad angular o ángulo de giro), esto quiere decir que el algoritmo DTW sólo entrega una medida de mínima distancia por cada comparación entre vectores de referencia y el vector de prueba. En nuestro trabajo se consideraron vectores de referencia principales de dos dimensiones (ver tabla 2.5) ya que representan de mejor manera a los eventos de conducción, por lo que DTW entrega dos medidas de mínima distancia y debido a KNN sólo requiere una medida por cada comparación entre los vectores de referencia y el vector de prueba, estas dos mediciones se suman por medio de la distancia de Manhattan [39] ya que una de las consideraciones de éste trabajo es que se produzca la clasificación de los eventos en el menor tiempo posible, utilizando técnicas de bajo requerimiento computacional sin comprometer de sobremanera la tasa de clasificaciones, y la distancia de Manhattan utiliza únicamente las operaciones de adición y sustracción, misma razón por la cual no se consideró sumar las dos mínimas distancias por medio de la distancia Euclidiana [39] que además considera las operaciones de potencia y raíz cuadrada.

Como se mencionó en el apartado 2.3.1, la velocidad angular en el eje z (G_z) y el ángulo de giro en el eje z (E_z) representan los eventos de la categoría “Vueltas”. La velocidad angular proporciona la velocidad con que se realiza una vuelta a la izquierda si la gráfica de su serie de datos se posiciona en valores positivos y a la derecha si se posiciona en valores negativos (ver figuras 2.7, 2.9, 2.11 y 2.13). El ángulo de giro muestra un comportamiento similar, una vuelta a la izquierda se realiza cuando la gráfica de su serie de datos recorre ángulos de mayor a menor valor y de forma inversa para las vueltas a la derecha (ver figuras 2.8, 2.10, 2.12 y 2.14). Debido a lo anterior, nos percatamos que es posible la combinación de la estadística descriptiva y KNN para clasificar los eventos de la categoría “Vueltas” y también para diferenciar dicha categoría con los dos restantes, “Velocidad” y “Camino”. A los vectores de características de referencia en todas las categorías se les obtuvieron los valores máximos de velocidad angular en el eje z (G_z) y para el ángulo de giro en el eje z (E_z) se obtuvieron los ángulos totales de movimiento, realizando la diferencia entre el ángulo final y el ángulo inicial del evento. Si se grafican en un plano los valores mencionados anteriormente se obtiene la siguiente figura:

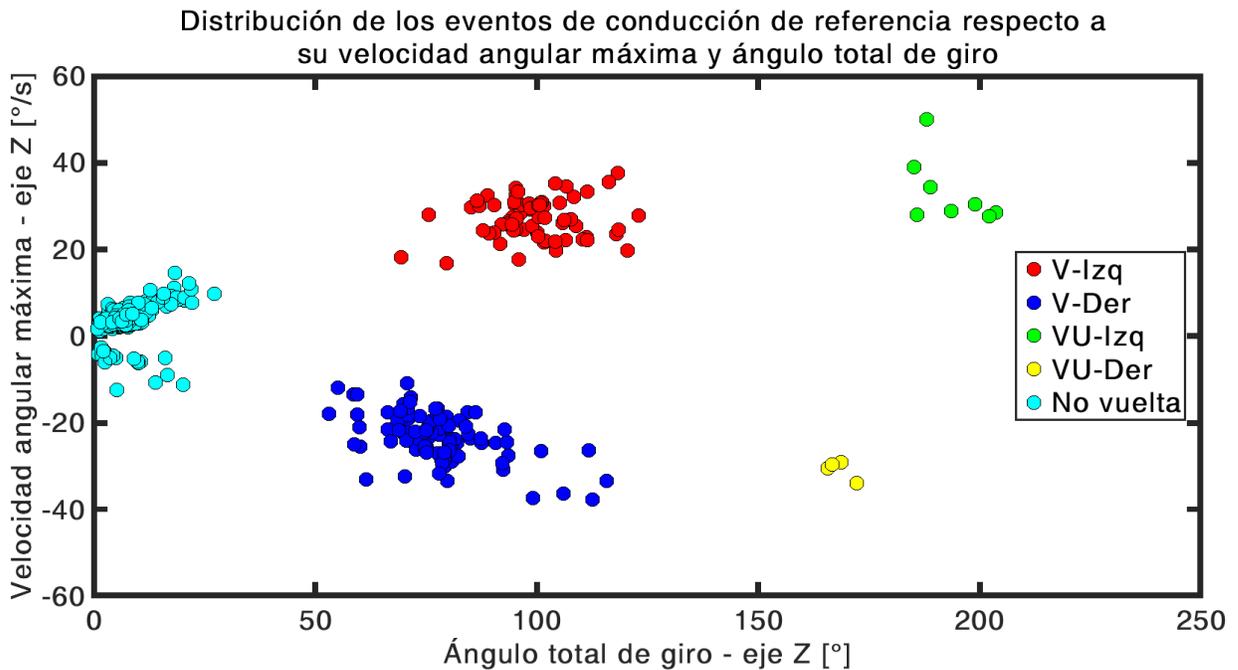


Figura 2.23: Gráfica de la velocidad angular máxima contra el ángulo total de giro de los vectores de características de referencia de los eventos de conducción en todas las categorías. Los puntos marcados con “No vuelta” son eventos pertenecientes a las categorías “Velocidad” y Camino” indistintamente.

De la figura anterior, se observa que los eventos pertenecientes a las diferentes categorías se agrupan en diferentes cúmulos bien definidos y pueden ser clasificados utilizando únicamente KNN, sin la necesidad de algoritmos más complejos como SVM.

Entonces, una primera clasificación utiliza la información de la estadística descriptiva junto con el algoritmo KNN. Si el vector de características pertenece a un evento dentro de la categoría “Vueltas”, la clasificación ocurre de manera directa, se asigna la clase. En otro caso, se realiza la clasificación por medio de la combinación de los algoritmos DTW y KNN.

En resumen, los pasos del clasificador de eventos de conducción son los siguientes:

1. **Recepción de los vectores de características de los eventos de referencia y prueba.** En esta etapa se ingresan los vectores de referencia y de prueba al clasificador.
2. **Primera clasificación: Distinguir entre diferentes tipos de vueltas y cualquier otro evento.** Se utiliza la combinación de la estadística descriptiva y KNN. Si el evento pertenece a alguno de la categoría “Vueltas”, KNN asigna la clase inmediatamente y termina, caso contrario se procede al punto 3.
3. **Segunda clasificación: Medición del grado de similitud entre los vectores de referencia y el vector de prueba.** Se utiliza la combinación de los algoritmos DTW y KNN para clasificar el evento que pertenece a las categorías “Velocidad” o “Camino” y termina.

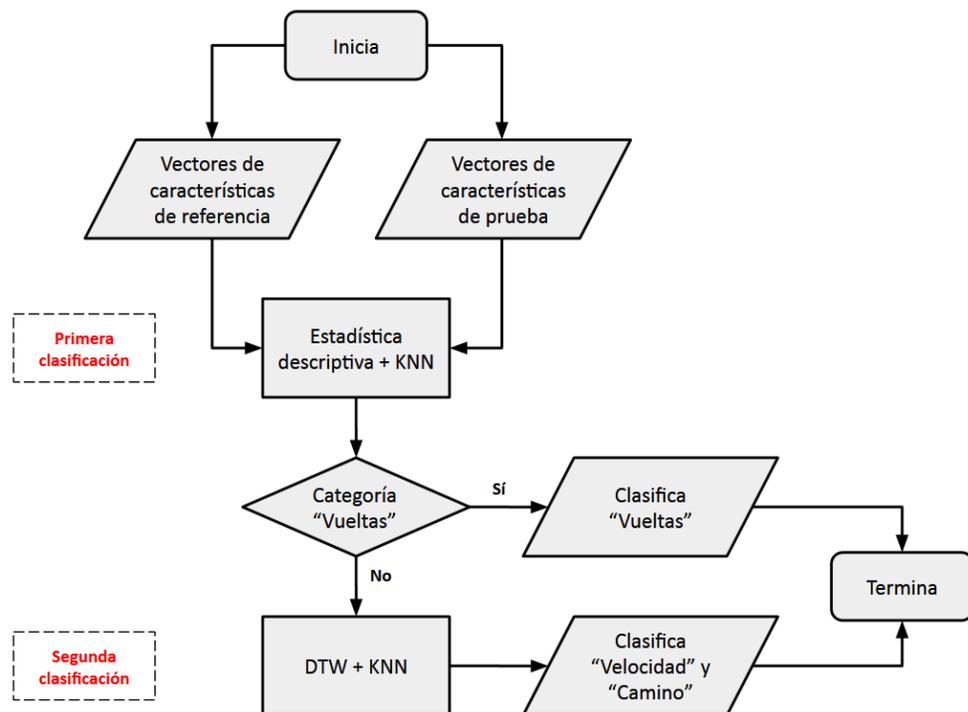


Figura 2.24: Diagrama de flujo del clasificador de dos etapas.

En el siguiente capítulo se describe la implementación del sistema MEMS con un sistema embebido Raspberry PI, además se presentan los resultados obtenidos junto con la comparación contra las principales investigaciones mostradas en la tabla 1.1.

CAPÍTULO 3

IMPLEMENTACIÓN Y DESEMPEÑO DEL SISTEMA

En este capítulo se expone la implementación del sistema para el almacenamiento de tramas de información que construyen la base de registros de referencia y prueba, además se comparan los resultados obtenidos con trabajos similares mediante la tasa de clasificaciones correctas y la matriz de confusión que muestra las clasificaciones por tipo de evento.

3.1. IMPLEMENTACIÓN DEL SISTEMA

El sistema para la obtención de muestras de los eventos de conducción fue construido a partir del sensor MEMS modelo JY901B, mostrado en la tabla A.1 del Anexo A y las tramas de información fueron almacenadas por una computadora embebida modelo Raspberry PI 3B, mostrada en la tabla A.2 del Anexo A. Así mismo, el sistema tiene comunicación con un teléfono inteligente por medio de Bluetooth para la interacción con el usuario. En las figuras 3.1A y 3.1B se observa su construcción.

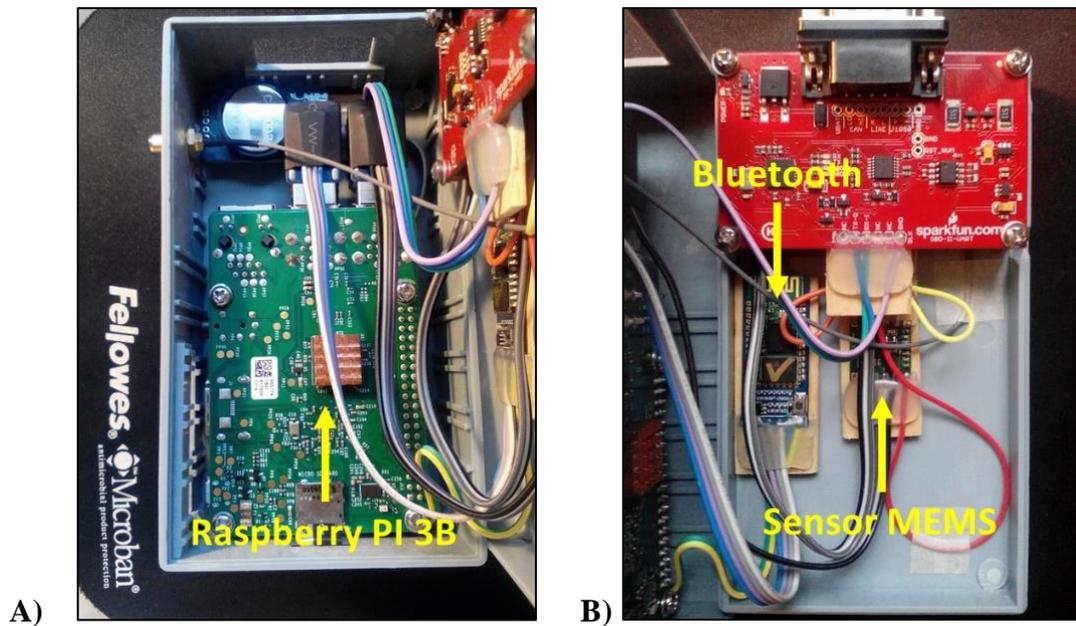


Figura 3.1: Sistema para el almacenamiento de muestras de aceleración, velocidad angular y ángulo de inclinación: A) Computadora embebida Raspberry PI 3B, B) Modulo Bluetooth y sensor MEMS.

El sistema se colocó suspendido rígidamente del parabrisas como se muestra en la figura 3.2. Con esto y mediante un teléfono, un usuario puede iniciar la calibración de los sensores e indicar el inicio, fin y tipo de evento que ocurrió, para conformar la base de registros de referencia o prueba.



Figura 3.2: Sistema para el almacenamiento de muestras, colocado en el parabrisas del automóvil.

El código que se ejecuta en el Raspberry PI 3B para controlar el modulo Bluetooth y el almacenamiento de las muestras, fue escrito en *lenguaje C* y la interacción con el sistema se realiza por medio de la aplicación *Serial Bluetooth Terminal* [43] para teléfonos inteligentes con sistema operativo Android. Atraves de ella se envían y reciben comandos para la calibración y registro de los diferentes eventos de conducción.

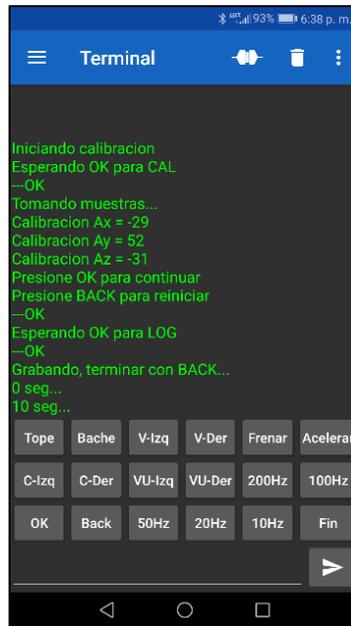


Figura 3.3: Aplicación *Serial Bluetooth Terminal* para el envío y recepción de comandos con el sistema de almacenamiento.

Terminada una sesión de recolección de muestras y mediante el ambiente de cómputo *Matlab*, se extraen los vectores de rasgos característicos y se reduce el ruido mediante un Filtro de Media Móvil (MAF), para finalmente ser almacenadas en la base de registros de referencia o prueba. Si bien las muestras que conforman la base de datos de referencia son segmentadas con la intervención del autor, las muestras de prueba son segmentadas de forma automática, para conformar un sistema automático de clasificación de eventos de conducción. En el siguiente apartado se trata la segmentación automática de los eventos de interés mediante la Media Móvil Simple (SMA).

3.2. SEGMENTACIÓN AUTOMÁTICA DE EVENTOS DE INTERÉS

Las muestras que conforman la base de vectores de características de referencia y algunas muestras de prueba fueron cuidadosamente segmentadas por el autor, para así evaluar el desempeño del sistema y considerar este trabajo de investigación como del tipo “Clasificador” o semi-automático (ver tabla 1.1). Es importante mencionar que este tipo de metodologías sólo comprueban el funcionamiento de los algoritmos de clasificación en condiciones cercanas a las ideales (la detección del inicio y fin de la posible ocurrencia de un evento de prueba se realiza con la intervención de una persona), y con ello se obtienen altas tasas de clasificaciones correctas como lo reportado por Mitrovic [3], que obtuvo 98% de eventos clasificados correctamente utilizando Modelos Ocultos de Markov (HMM) en su trabajo del tipo “Clasificador”. Hacer intervenir a una persona en la detección de un evento de prueba resulta impráctico si se requiere de un sistema automático donde el trabajo sea considerado del tipo “Segmentación y Clasificación”.

El aparente costo de reemplazar a una persona que cuidadosamente segmenta las muestras de prueba, por un sistema automatizado, es que la tasa de clasificaciones puede disminuir. En los resultados obtenidos por Mitrovic [3] y nuestros resultados que se muestran en la sección 3.3.1 *Pruebas y Resultados*, se observa que una persona segmenta de mejor manera las muestras de prueba a comparación de un programa de cómputo, lo cual provoca altas tasas de clasificaciones correctas.

En esta investigación se retoma el uso de la Media Móvil Simple (SMA) [40] como lo hace Jhonson [7] y Minglin [23], para la detección automática de la posible ocurrencia de un evento de prueba. La elección de esta técnica es debido a que su implementación es similar a la del Filtro de Media Móvil (MAF), además de que hereda algunos de sus beneficios. La detección del inicio y fin de la posible ocurrencia de un evento de prueba utilizando SMA se basa en la energía resultante del cambio en la aceleración, velocidad angular o ángulo de giro en alguno de sus ejes para una ventana de tamaño k de la i -ésima muestra actual.

$$SMA = \frac{B_a^2(i) + B_a^2(i-1) + \dots + B_a^2(i-k-1)}{k} \quad (3.1)$$

Donde B_a es alguna magnitud física proporcionada por el sensor MEMS en alguno de sus ejes x , y , z y $B_a(i)$, $B_a(i-1)$, \dots , $B_a(i-k-1)$ representan todas las k muestras en la ventana. Si SMA es mayor que un umbral superior t_i entonces $B_a(i-k-1)$ es el inicio del evento, y los subsecuentes valores de B_a son concatenados hasta que SMA sea menor que un umbral inferior t_f . Se eligieron las magnitudes de B_a como las magnitudes físicas de aceleración en el eje y (A_y), velocidad angular en el eje z (G_z) y aceleración en el eje z (A_z) para las categorías “Velocidad”, “Vueltas” y “Camino” respectivamente, porque como se mencionó en el apartado 2.3.1 *Extracción de Rasgos Característicos*, estas magnitudes, entre otras, son las que representan de mejor manera los eventos de conducción. Los umbrales de detección se obtuvieron mediante experimentación con base en los registros de referencia; se fijó el valor de $k = 50$ en la ventana para tener 4 valores SMA por segundo debido a que se obtienen muestras a una velocidad de 200 muestras por segundo, y se probaron de manera exhaustiva distintos valores de detección de la SMA hasta obtener una tasa de segmentación o reconocimiento de aproximadamente el 100%. Por ejemplo, para la categoría “Velocidad” que se muestra en la figura 3.4, se eligió el umbral superior t_i igual al inferior t_f y dicho umbral unificado para el evento Frenar es de $SMA_F = 0.038g$ y para el evento Acelerar es de $SMA_A = 0.026g$. De manera similar se eligieron los umbrales de detección para los eventos de las categorías “Vueltas” y Camino” que se muestran en las figuras 3.5 y 3.6 respectivamente.

Categoría: Velocidad

Umbral de detección. Frenar: $SMA_F = 0.038g$, Acelerar: $SMA_A = 0.026g$

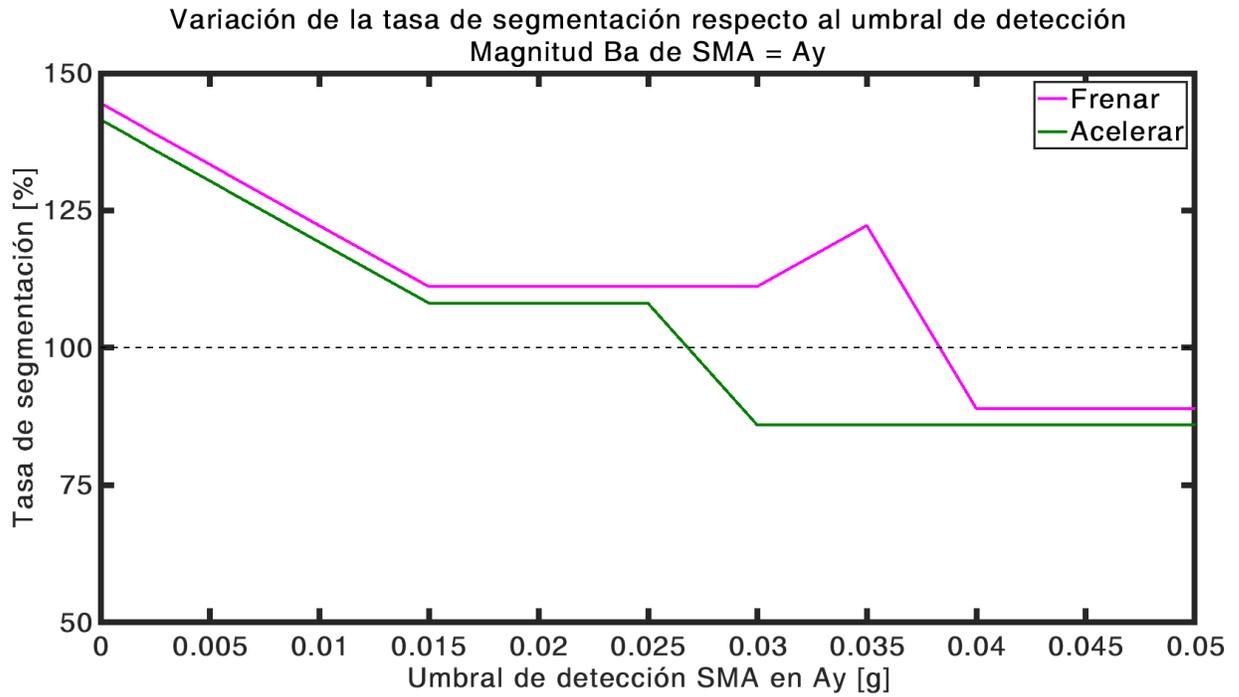


Figura 3.4: Tasa de segmentación o reconocimiento para los eventos de la categoría “Velocidad”.
Frenar: $SMA_F = 0.038g$, Acelerar: $SMA_A = 0.026g$.

Categoría: Vueltas

Umbral de detección. Vuelta a la izquierda: $SMA_{VI} = 260^\circ/s$, Vuelta a la derecha: $SMA_{VD} = 190^\circ/s$, Vuelta a la izquierda en U: $SMA_{VIU} = 670^\circ/s$, Vuelta a la derecha en U: $SMA_{VDU} = 670^\circ/s$

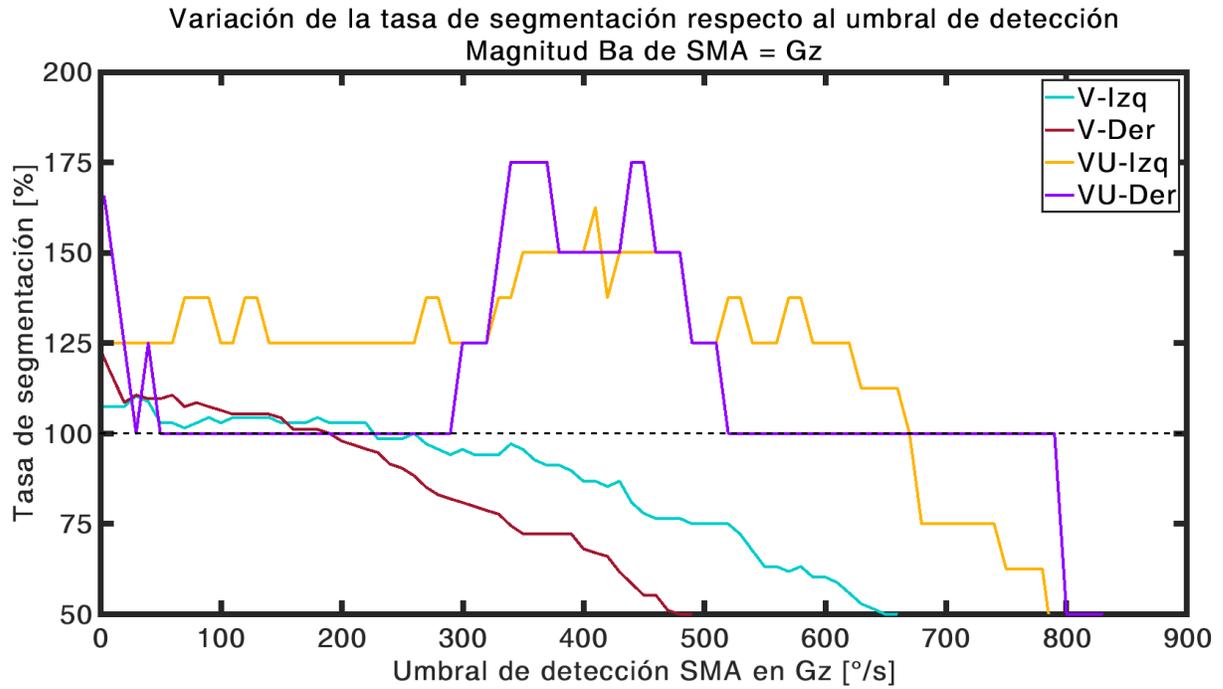


Figura 3.5: Tasa de segmentación o reconocimiento para los eventos de la categoría “Vueltas”.

Vuelta a la izquierda: $SMA_{VI} = 260^\circ/s$, Vuelta a la derecha: $SMA_{VD} = 190^\circ/s$.

Vuelta a la izquierda en U: $SMA_{VIU} = 670^\circ/s$, Vuelta a la derecha en U: $SMA_{VDU} = 670^\circ/s$.

Categoría: Camino

Umbrales de detección. Tope: $SMA_T = 0.021g$, Bache: $SMA_B = 0.0076g$

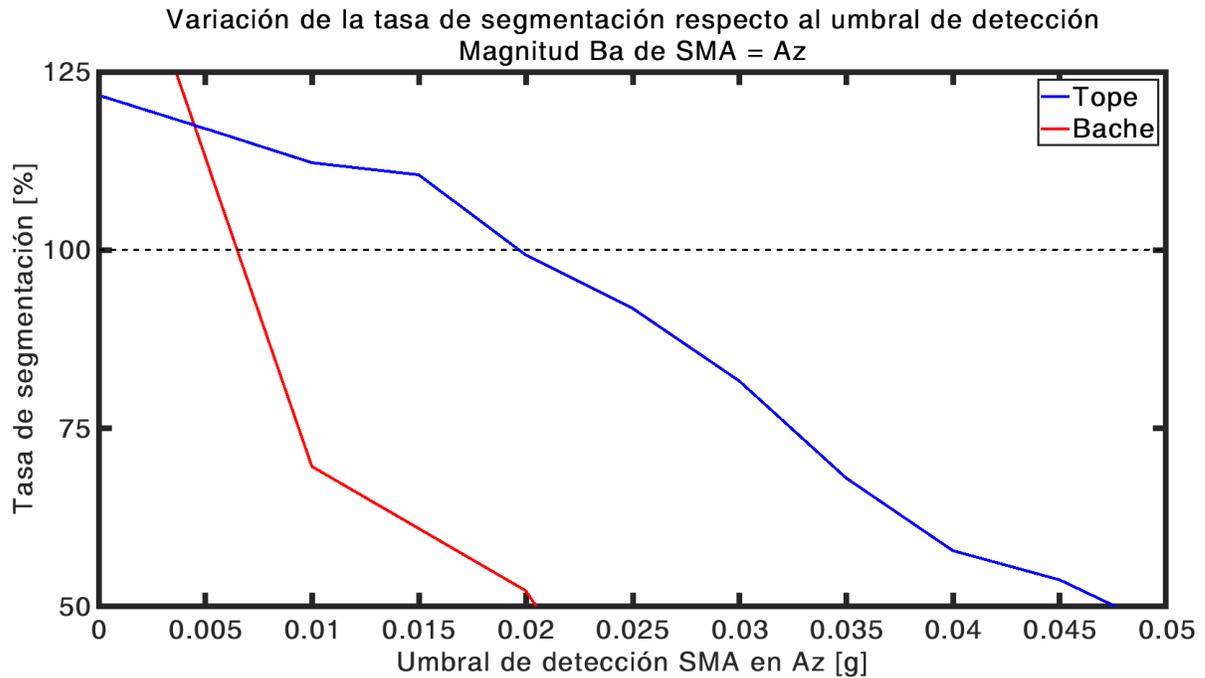


Figura 3.6: Tasa de segmentación o reconocimiento para los eventos de la categoría “Camino”.

Tope: $SMA_T = 0.021g$, Bache: $SMA_B = 0.0076g$.

En la siguiente tabla se muestran las magnitudes físicas y los umbrales seleccionados por categoría y tipo de evento.

CATEGORÍA	EVENTO	MAGNITUD B_a	UMBRAL SMA $t_i = t_f$
Velocidad	Frenar	A_y	$SMA_F = 0.038g$
	Acelerar		$SMA_A = 0.026g$
Vueltas	Vuelta a la izquierda	G_z	$SMA_{VI} = 260^\circ/s$
	Vuelta a la derecha		$SMA_{VD} = 190^\circ/s$
	Vuelta a la izquierda en U		$SMA_{VIU} = 670^\circ/s$
	Vuelta a la derecha en U		$SMA_{VDU} = 670^\circ/s$
Camino	Tope	A_z	$SMA_T = 0.021g$
	Bache		$SMA_B = 0.0076g$

Tabla 3.1: Magnitudes B_a y umbrales de detección SMA por cada evento de conducción.

Una vez conformado el sistema automático de clasificación y la segmentación automática de eventos, se procede a mostrar los resultados obtenidos por este trabajo de investigación.

3.3. RESULTADOS DEL SISTEMA

Teniendo en consideración lo expuesto en el Capítulo 2 para la conformación de un método que permita clasificar eventos de conducción, consideraciones previas a la toma de muestras de aceleración, velocidad angular y ángulo de inclinación, extracción de rasgos característicos, elección de algoritmos de clasificación, segmentación automática de eventos de prueba y la implementación del sistema, se muestran los resultados obtenidos por la propuesta del sistema automático de clasificación. Estos resultados incluyen diversas pruebas al sistema, gráficas de su rendimiento respecto a la tasa de clasificaciones correctas, la matriz de confusión que muestra las clasificaciones por tipo de evento y finalmente la comparación de los resultados contra los alcanzados en los trabajos relacionados que consideramos sobresalientes.

Para evaluar el desempeño del sistema automático de clasificación se consideraron un total de 200 eventos de prueba, divididos equitativamente por cada tipo de evento de conducción a clasificar (ver tabla 2.1). Se realizaron tres pruebas, la primera y segunda para evaluar únicamente el desempeño del clasificador y considerar este trabajo de investigación como del tipo “Clasificador”, en el cual la segmentación de los eventos de prueba fue realizada por el autor, y la tercera para evaluar el sistema junto con la segmentación automática y que la investigación pueda ser considerada del tipo “Segmentación y Clasificación”.

3.3.1. PRUEBAS Y RESULTADOS

Prueba 1: Desempeño del clasificador. Distorsión de Tiempo Dinámico (DTW) y K-Vecinos más Cercanos (KNN).

Considerando únicamente la combinación de los algoritmos DTW-KNN, se obtuvo el comportamiento mostrado en la siguiente figura, respecto a la tasa de clasificación al variar el parámetro K de KNN.

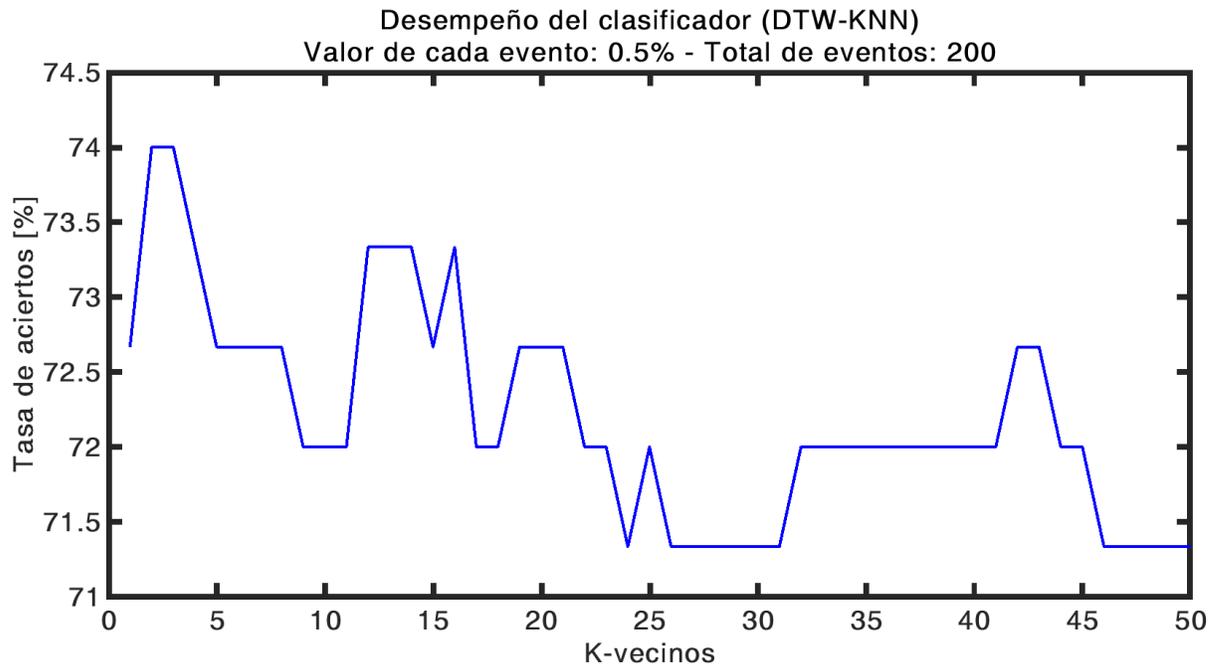


Figura 3.7: Tasa de aciertos respecto al valor de K al utilizar únicamente DTW y KNN.

Se observa que la tasa de clasificación oscila entre 71.5 y 74%. La mejor tasa de aciertos es del 74% con un valor de K entre 2 y 3. Para valores de K mayores a 50 la tasa de clasificación se mantiene en 71.5%. En la siguiente figura se muestra la matriz de confusión para la mejor tasa de clasificación del 74%.

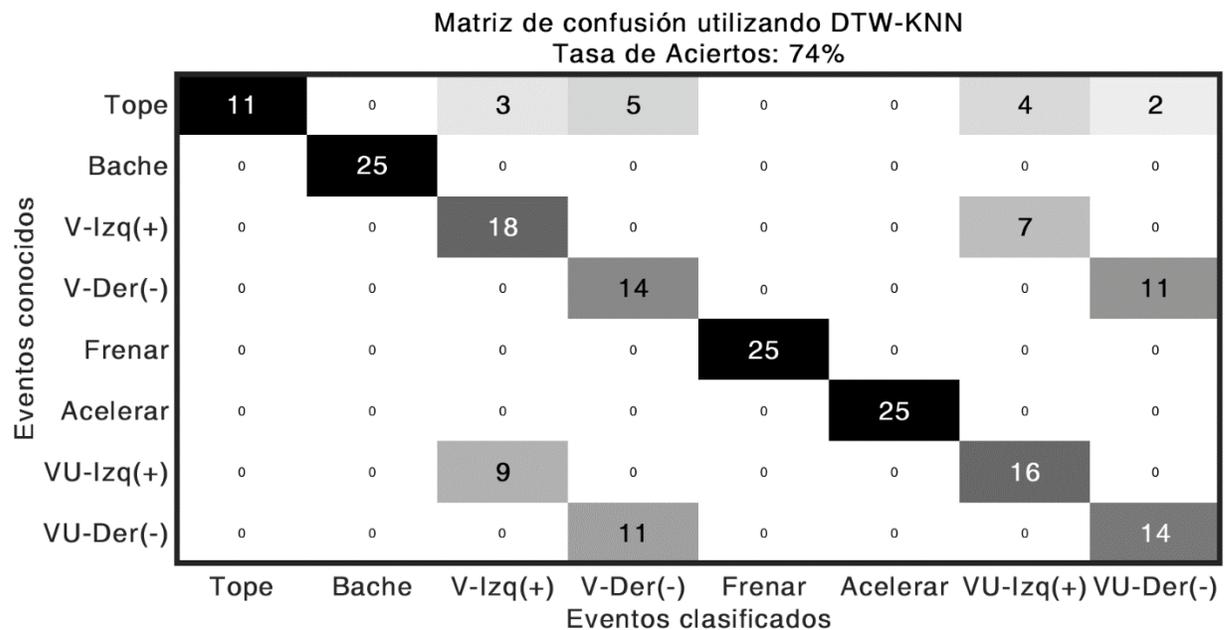


Figura 3.8: Matriz de confusión de la mejor tasa de clasificación del 74% al utilizar únicamente DTW y KNN.

La matriz de confusión muestra los aciertos y errores por cada tipo de evento, en específico con que etiqueta se clasificaron incorrectamente. De la figura 3.5 anterior, se observa que las clasificaciones erróneas ocurren en eventos del tipo Bache, Tope, Vuelta a la izquierda, a la derecha, Vuelta a la izquierda en U y a la derecha en U con eventos de la categoría “Vueltas”. Por ejemplo, para el caso del evento Tope, las clasificaciones incorrectas son debido a que en ocasiones es necesario girar el automóvil antes de pasar un tope ya que las condiciones de las calles de la Ciudad de México no son óptimas y se desea evitar algún daño al automóvil. Para el caso de la clasificación errónea con algún tipo de vuelta, se previó este comportamiento y una posible solución se expuso en el apartado 2.4.3 *Combinación de DTW y KNN para la Clasificación*, utilizando una primera clasificación con Estadística descriptiva y KNN, para posteriormente realizar la segunda clasificación con DTW-KNN, además esta misma solución ayudó a distinguir la intención de girar el automóvil antes de pasar un tope a diferencia de dar una vuelta.

Prueba 2: Desempeño del Clasificador. Estadística descriptiva con KNN y DTW-KNN.

Se consideran dos etapas de clasificación, la primera con Estadística descriptiva y KNN para catalogar los eventos de la categoría “Vueltas” y para diferenciar dicha categoría con los dos restantes, “Velocidad” y “Camino”. La segunda clasificación consta de la combinación de los algoritmos DTW y KNN. El valor de K en KNN de la primera clasificación se mantiene constante en 3 para reducir la posibilidad de empate y también debido a que los cúmulos de la figura 2.23 están bien definidos. Con lo anterior se obtiene el comportamiento mostrado en la siguiente figura, respecto a la tasa de clasificación al variar el parámetro K de KNN en el segundo clasificador.

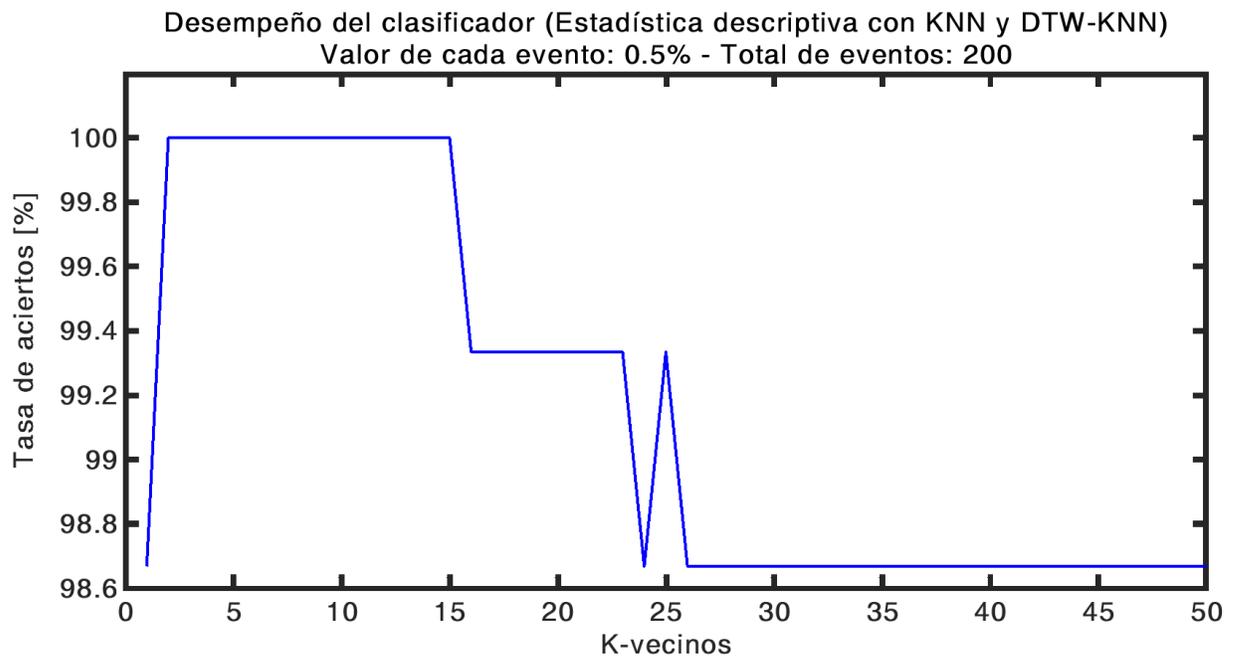


Figura 3.9: Tasa de aciertos respecto al valor de K en el segundo clasificador, al utilizar Estadística descriptiva con KNN y DTW-KNN.

Se observa que la tasa de clasificación oscila entre 98.7 y 100%. La mejor tasa de aciertos es del 100% con un valor de K entre 2 y 15. Para valores de K mayores a 30 la tasa de clasificación se mantiene en 98.7%. En la siguiente figura se muestra la matriz de confusión para la mejor tasa de clasificación del 100%.

Matriz de confusión utilizando Estadística descriptiva con KNN y DTW-KNN
Tasa de Aciertos: 100%

Eventos conocidos	Tope	25	0	0	0	0	0	0	
	Bache	0	25	0	0	0	0	0	
	V-lzq(+)	0	0	25	0	0	0	0	
	V-Der(-)	0	0	0	25	0	0	0	
	Frenar	0	0	0	0	25	0	0	
	Acelerar	0	0	0	0	0	25	0	
	VU-lzq(+)	0	0	0	0	0	0	25	
	VU-Der(-)	0	0	0	0	0	0	0	25
		Eventos clasificados	Tope	Bache	V-lzq(+)	V-Der(-)	Frenar	Acelerar	VU-lzq(+)

Figura 3.10: Matriz de confusión de la mejor tasa de clasificación del 100% al utilizar Estadística descriptiva con KNN y DTW-KNN.

De la figura 3.7 anterior, se observa que no existen clasificaciones erróneas y las clasificaciones incorrectas de la Prueba 1, mostradas en la figura 3.5, fueron corregidas. El uso de dos etapas de clasificación por medio de Estadística descriptiva con KNN y DTW-KNN resulta en altas tasas de clasificación que oscilan entre 98.7 y 100%. Cabe recordar que estas dos pruebas son para evaluar únicamente el desempeño del clasificador y considerar este trabajo de investigación como del tipo “Clasificador”, en el cual la segmentación de los eventos de prueba fue realizada por el autor, en la siguiente prueba se evalúa el sistema junto con la segmentación automática para que la investigación pueda ser considerada del tipo “Segmentación y Clasificación”.

Prueba 3: Desempeño del clasificador automático. Estadística descriptiva con KNN, DTW-KNN y segmentación automática.

Considerando el clasificador de dos etapas de la Prueba 2 y la entrada de muestras de prueba mediante la segmentación automática con ayuda de la SMA, se obtuvo el comportamiento mostrado en la siguiente figura, respecto a la tasa de clasificación al variar el parámetro K de KNN en el segundo clasificador.

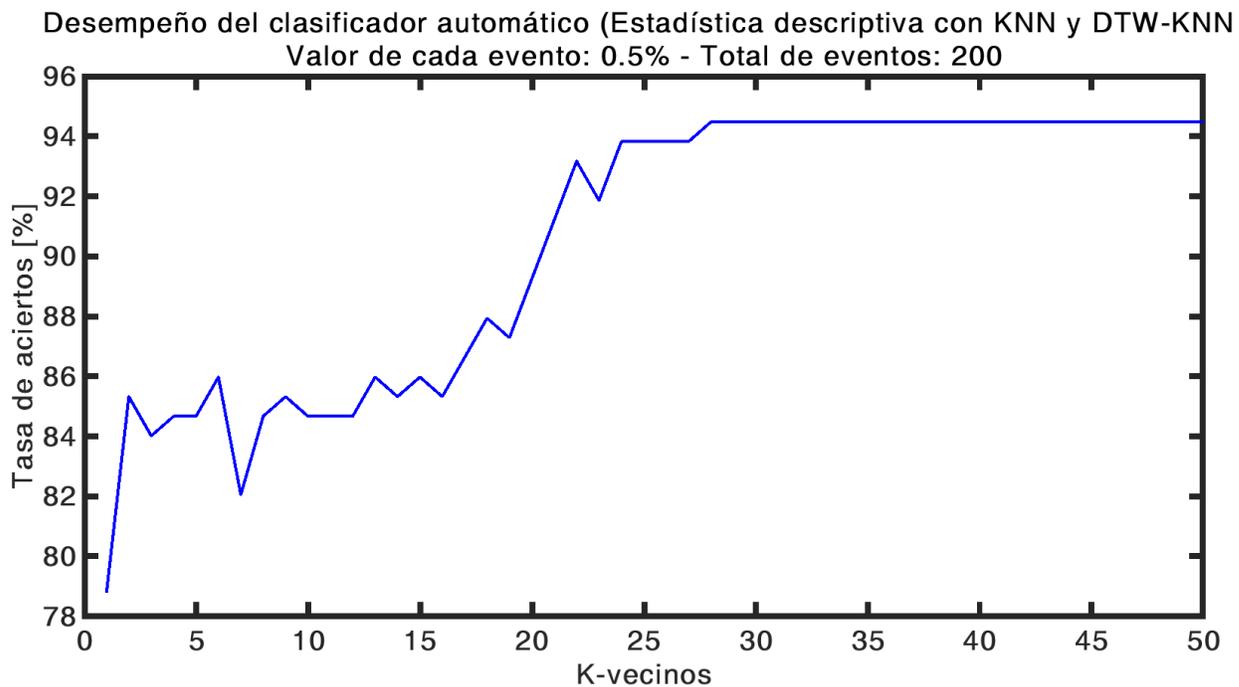


Figura 3.11: Tasa de aciertos respecto al valor de K en el segundo clasificador, al utilizar Estadística descriptiva con KNN, DTW-KNN y Segmentación automática.

Se observa que la tasa de clasificación oscila entre 79 y 94%. La mejor tasa de aciertos es del 94% con un valor de K mayor o igual a 28. Para valores de K mayores a 28 la tasa de clasificación se mantiene en 94%. En la siguiente figura se muestra la matriz de confusión para la mejor tasa de clasificación del 94%.

De la figura 3.8 anterior, se observa que el costo de reemplazar la segmentación por medio de una persona a la segmentación automática por medio de la SMA, es la reducción en la tasa de clasificaciones correctas y el aumento del valor K para obtener la mejor tasa de clasificación. Era de esperarse este comportamiento ya que un usuario puede segmentar cuidadosa y fielmente el inicio y fin de la ocurrencia de un evento de conducción al observar y conocer las gráficas de los vectores de características que representan a los eventos. Aunque la segmentación por medio de la SMA no es perfecta, resulta en una alta tasa de clasificaciones correctas del 94% que compite y en algunos casos supera los resultados obtenidos por otras metodologías relacionadas a la clasificación de eventos de conducción.

Matriz de confusión utilizando Estadística descriptiva con KNN, DTW-KNN y Segmentación automática. Tasa de Aciertos: 94%

Eventos conocidos	Topo	Bache	V-Izq(+)	V-Der(-)	Frenar	Acelerar	VU-Izq(+)	VU-Der(-)
Topo	24	1	0	0	0	0	0	0
Bache	1	24	0	0	0	0	0	0
V-Izq(+)	0	0	25	0	0	0	0	0
V-Der(-)	0	0	0	25	0	0	0	0
Frenar	1	0	0	0	24	0	0	0
Acelerar	0	0	0	0	0	25	0	0
VU-Izq(+)	0	0	4	0	0	0	21	0
VU-Der(-)	0	0	0	5	0	0	0	20
Eventos clasificados	Topo	Bache	V-Izq(+)	V-Der(-)	Frenar	Acelerar	VU-Izq(+)	VU-Der(-)

Figura 3.12: Matriz de confusión de la mejor tasa de clasificación del 94% al utilizar Estadística descriptiva con KNN, DTW-KNN y Segmentación automática.

De la figura 3.9 anterior, se observa que las clasificaciones erróneas ocurren principalmente en eventos del tipo Vuelta a la izquierda en U y Vuelta a la derecha en U. Por ejemplo, para el caso del evento Vuelta a la izquierda en U, hay una alta posibilidad de que las clasificaciones incorrectas fueron debido a que la SMA detectó el inicio o fin de la ocurrencia del evento de manera errónea, lo cual segmentó la trama de información en un intervalo en el que el ángulo de giro se considera asociado al evento Vuelta a la izquierda.

En el apartado siguiente se extiende la tabla 1.1 de las investigaciones que consideramos más relevantes, con los resultados obtenidos en este trabajo y se realizan las observaciones pertinentes.

3.3.2. COMPARACIÓN DE RESULTADOS

Los resultados obtenidos en este trabajo de investigación muestran que es viable el diseño y construcción del sistema de clasificación de eventos de conducción propuesto, ya que se obtiene una tasa de clasificación del 100% al evaluar el desempeño del clasificador y una tasa del 94% cuando se evalúa el sistema automático. Entonces, es de interés la comparación de estos resultados contra otras diferentes investigaciones relacionadas, porque permitirá saber el alcance logrado. La tabla siguiente muestra dicha comparación.

AUTORES	TRABAJO REALIZADO	CATEGORÍAS DETECTADAS	ADQUISICIÓN DE DATOS	MÉTODO DE CLASIFICACIÓN	CLASIFICACIÓN CORRECTA
Sistema propuesto	Clasificación	Velocidad Vueltas Camino	Sistema embebido (MEMS)	DTW KNN	100%, DTW-KNN
Sistema propuesto	Segmentación y Clasificación	Velocidad Vueltas Camino	Sistema embebido (MEMS)	DTW KNN	94%, DTW-KNN
Mitrovic, 2005 [3]	Clasificación	Velocidad Vueltas Glorieta	Sistema embebido (MEMS)	HMM	98%, HMM
Jhonson, et. al., 2011 [7]	Segmentación y Clasificación	Velocidad Vueltas Carril	Teléfono Inteligente	DTW KNN	91%, DTW-KNN
Song, et. al., 2012 [18]	Segmentación y Clasificación	Velocidad Vueltas	Teléfono Inteligente	DTW KNN	93%, DTW-KNN
Sathyanarayana, et. al., 2012 [13]	Clasificación	Velocidad Vueltas Carril	Automóvil (OBD + CAN)	KNN SVM	81%, SVM
Ly, et. al., 2013 [12]	Clasificación	Velocidad Vueltas	Automóvil (OBD + CAN)	K-Means SVM	80%, K-Means
Minglin, et. al., 2016 [23]	Segmentación y Clasificación	Velocidad Vueltas Carril	Sistema embebido (MEMS)	KNN SVM	93%, SVM

Tabla 3.2: Comparación de los resultados obtenidos en este trabajo contra diferentes investigaciones sobre la clasificación de eventos de conducción.

La tabla anterior es una extensión de la tabla 1.1, donde se incluyen los resultados obtenidos por el sistema de clasificación propuesto. Se tiene que esta investigación es del tipo “Clasificación” ya que la Prueba 2 evalúa únicamente el desempeño del clasificador obteniendo una tasa de aciertos del 100%, a comparación de los trabajos de Mitrovic, Sathyanarayana y Ly que obtuvieron una tasa del 98, 81 y 80% respectivamente, además se tiene la ventaja de que en esta investigación empleamos métodos de clasificación de bajo costo computacional (DTW y KNN) a comparación de los HMM. También, se considera que esta investigación es del tipo “Segmentación y Clasificación” porque la Prueba 3 considera la segmentación automática de los eventos de prueba obteniendo una tasa del 94%, a comparación de lo reportado por Jhonson, Song, y Minglin que obtuvieron una tasa del 91, 93 y 93% respectivamente. Cabe resaltar que la tasa de clasificación del 94% debe considerarse como la que describe de mejor manera el rendimiento del sistema si este requiere ser incorporado como parte de una aplicación práctica, ya que como se mencionó anteriormente, para lograr una tasa del 100% es necesario segmentar los eventos de prueba bajo supervisión de un usuario. Para los eventos detectados, nuestra propuesta retoma dos categorías comunes en los trabajos relacionados: “Velocidad” y “Vueltas”. Además, se propone una tercera categoría: “Camino”, no considerada anteriormente por las investigaciones relacionadas, donde se incluyen eventos del tipo Tope y Bache. Finalmente, en el capítulo siguiente se da cierre a este trabajo, presentando las conclusiones pertinentes y el trabajo a futuro que puede derivarse de esta investigación.

CAPÍTULO 4

CONCLUSIONES Y TRABAJO FUTURO

4.1. CONCLUSIONES

El trabajo teórico y experimental realizado en esta investigación, permite establecer las siguientes conclusiones:

- Se estableció una metodología para crear un sistema automático de clasificación de eventos de conducción, basado en Distorsión de Tiempo Dinámico (DTW) y K-Vecinos más Cercanos (KNN).
- Se validó la metodología propuesta implementado, a partir de esta, un sistema automático de clasificación de eventos. Este sistema incluyó la creación de una base de registros de eventos de conducción de referencia, módulos de preprocesamiento de los registros, basado en la extracción de rasgos característicos de los eventos, filtrado de las series de datos mediante un filtro MAF y como sistema de clasificación la combinación de los algoritmos DTW y KNN.
- La tasa de clasificaciones correctas obtenida en las pruebas realizadas al sistema automático (ver figuras 3.11 y 3.12), permiten concluir que es posible crear un sistema de clasificación de eventos de conducción a partir de diferentes magnitudes físicas como la aceleración, velocidad angular y ángulo de giro.
- Los resultados presentados en las figuras 3.7 y 3.8 muestran que solamente la combinación de los algoritmos DTW-KNN, para los eventos de conducción que consideramos, no tiene buen desempeño como clasificador, por lo que es necesario combinarlo con otros métodos para aumentar la tasa de clasificación, en éste trabajo se optó por utilizarlo junto con la Estadística descriptiva.

- Los resultados presentados en las figuras 3.9 y 3.11, garantizan que el sistema se estabiliza en un rango de K vecinos en el algoritmo KNN durante la clasificación.
- El desempeño mostrado por el sistema y representado por la gráfica de la variación de los K vecinos del algoritmo KNN (ver figura 3.11) muestra que la tasa de clasificaciones correctas aumenta al incrementar el valor de K . Este comportamiento indica que el valor de los K vecinos puede disminuir si se logran minimizar las distancias de similitud proporcionadas por DTW para cada evento de conducción.
- Considerando únicamente los resultados de las figuras 3.9 y 3.10, se obtiene una tasa de clasificación del 100% ya que, el ingreso de las muestras de prueba está cuidadosamente segmentadas por el autor, lo cual resulta impráctico si se requiere un sistema automático. El costo de automatizar el sistema y utilizar el clasificador junto con una etapa de segmentación mediante la Media Móvil Simple (SMA) resulta en una disminución de la tasa de clasificaciones correctas al 94%.
- De los resultados mostrados en la sección 3.3.2 *Comparación de Resultados*, se observa que en sistema automático mediante DTW y KNN, tiene mejor desempeño que los sistemas SVM y K-Means, aun cuando las diferencias se encuentren en un intervalo entre el 1% y 14%.

Las conclusiones realizadas permiten verificar el logro de los objetivos mencionados en las secciones 0.5 *Objetivo General* y 0.6 *Objetivos Particulares*. También confirman que Distorsión de Tiempo Dinámico (DTW) y K-Vecinos más Cercanos (KNN) son técnicas exitosas que, con base en la metodología propuesta, puede mejorar el desempeño de otros sistemas de clasificación, como se observa para los sistemas SVM y K-Means. Por su relevancia en el contexto de la investigación, puede mencionarse la creación de una base de registros que incluye eventos como Tope y Bache, lo cual contribuye al acervo pues no han sido considerados anteriormente por otros autores, debido a las buenas condiciones de las calles donde se realizaron las investigaciones. Además, se resalta el clasificador de dos etapas de la sección 2.4.3 *Combinación de DTW y KNN para la Clasificación*, ya que no ha sido considerado anteriormente por otros autores e incluye la unificación de la Estadística descriptiva con KNN y DTW-KNN. En la parte de preprocesamiento y clasificación, la propuesta constituye una opción sencilla y viable que puede implementarse en una computadora embebida. Por último, se resalta la contribución del trabajo en su conjunto, ya que permite una implementación de bajo costo computacional y monetario, de un sistema automático de clasificación de eventos de conducción basado en DTW y KNN, lo cual resulta novedoso en México.

4.2. TRABAJO FUTURO

Como parte principal del trabajo a futuro propuesto se encuentra, representar los eventos de conducción con las magnitudes físicas en los diferentes ejes que no se consideraron, a fin de mejorar la resolución entre las distribuciones de la tasa de clasificaciones correctas e incorrectas, del sistema mediante Distorsión de Tiempo Dinámico (DTW) y K-Vecinos más Cercanos (KNN) y aumentar así su desempeño. La base de registros de vectores de características puede complementarse incrementando el número de eventos registrados o promediando los registros almacenados. Algunos de éstos registros pueden ser utilizados para representar cambios sutiles entre diferentes formas de ejecutar un mismo evento de conducción. Por último, se propone realizar pruebas con el sistema DTW-KNN utilizando variaciones del algoritmo clásico DTW como el propuesto por Munich [33] utilizando Distorsión de Tiempo Dinámico Continuo (CDTW) o las condiciones de frontera propuestas por Itakura [42] para restringir las singularidades del algoritmo, a fin de observar su comportamiento en la medición de la similitud entre las series de datos, también realizar variaciones en el algoritmo KNN para la asignación de pesos a los diferentes vecinos, además de considerar algoritmos de aprendizaje maquina más sofisticados a comparación de umbrales de detección para la segmentación automática de los eventos de conducción de prueba.

APÉNDICE A

ANEXO 1

A.1. COMPARACIÓN ENTRE SISTEMAS MEMS

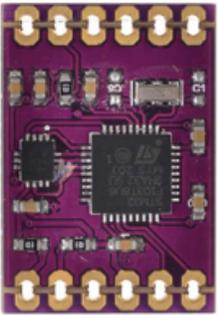
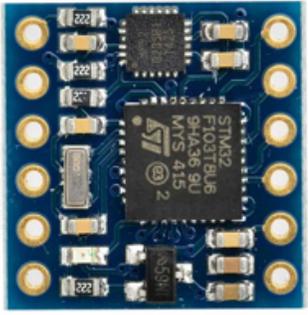
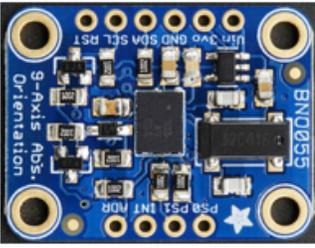
Figura			
Modelo	CJM316	GY-953	BNO055
Fabricante	CJMCU	CJMCU	Adafruit
Sensores	STMicroelectronics STM32F103, Bosch BMI160 (Gyr; Acc)	STMicroelectronics STM32F103, Invensense MPU9250 (Gyr; Acc y Mag)	Bosch BNO055 (Gyr; Acc, Mag, Euler, AccL)
Expansiones	No	No	No
Grados de libertad	6 (Gyr, Acc)	9 (Gyr, Acc y Mag)	9 (Gyr, Acc y Mag)
Salida de datos	Acc/Gyr	Acc/Gyr/Mag	Acc/Gyr/Mag/Temp
Fusion de datos	No	°Euler y Quaternion	°Euler; Quaternion y AccLineal
Ruido en sensores	Gyr: 0.07°/s, Acc: 180ug	Gyr: 0.1°/s, Acc: 300ug	Gyr: 0.3°/s, Acc: 150ug
Deriva en °Euler (°)	No aplica	2	2
Máxima frecuencia de muestras (Hz)	50	200	100
Maxima valocidad UART (bps)	115200	115200	115200

Tabla A.1: Comparación entre diferentes sistemas MEMS (continua).

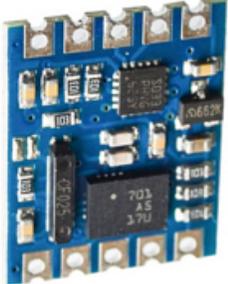
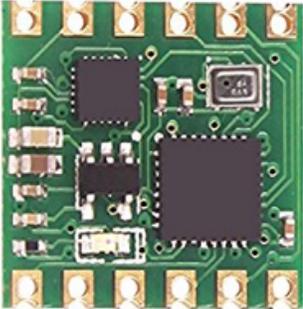
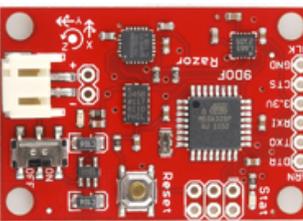
				
GY-BNO055	GY-955	JY901B	MM7150	SEN-10736
CIMCU	CIMCU	WitMotion	Microchip	Sparkfun
Bosch BNO055 (Gyr, Acc, Mag, Euler, Accl)	STMicroelectronics STM8S003, Bosch BNO055 (Gyr, Acc, Mag, Euler, Accl)	STMicroelectronics STM32F051, Invensense MPU9250 (Gyr, Acc y Mag)	Microchip SSC7150, Bosch BMG160 (Gyr), Bosch BMC150 (Acc y Mag)	Atmel ATmega328, Invensense ITG-3200 (Gyr), Analog Devices ADXL345 (Acc), Honeywell HMC5883L (Mag)
No	No	GPS	No	Bateria
9 (Gyr, Acc y Mag)	9 (Gyr, Acc y Mag)	9 (Gyr, Acc y Mag)	9 (Gyr, Acc y Mag)	9 (Gyr, Acc y Mag)
Acc/Gyr/Mag/Temp	Acc/Gyr/Mag	Acc/Gyr/Mag/Temp	Acc/Gyr/Mag	Acc/Gyr/Mag
°Euler, Quaternion y Acclineal	°Euler y Quaternion	°Euler y Quaternion	°Euler y Quaternion	°Euler
Gyr: 0.3°/s, Acc: 150ug	Gyr: 0.3°/s, Acc: 150ug	Gyr: 0.1°/s, Acc: 300ug	Gyr: 0.1°/s, Acc: 150ug	Gyr: 0.38°/s, Acc: Xmg
2	2	0.1	5	No indica
100	100	200	100	50
115200	115200	921600	I2C a 400KHZ	57600

Tabla A.1: Comparación entre diferentes sistemas MEMS.

A.2. COMPARACIÓN ENTRE COMPUTADORAS EMBEBIDAS

Figura			
Modelo	RaspberryPI 1B	RaspberrPI 3B	RaspberryPI Zero W
CPU	700MHz, 1 núcleo	1.2GHz, 4 núcleos	1GHz, 1 núcleo
RAM	512MB	1024MB	512MB
EMMC FLASH	No	No	No
USB	2	4	2 con expansión, 1 OTG
HDMI	HDMI	HDMI	miniHDMI
BT	No	Si	Si
WiFi	No	Si	Si
ETHERNET	Si	Si	No
Sistema Operativo	Raspbian	Raspbian	Raspbian
Almacenamiento	SD	micro SD	micro SD
Dimensiones	85mm x 54mm	85mm x 56mm	65mm x 30mm

Tabla A.2: Comparación entre diferentes computadoras embebidas (continua).

OrangePi Zero2+	OrangePi Lite	Onion Omega 2+	NanoPi Neo2	Banana PI M2 Zero
1.2GHz, 4 núcleos	1.6GHz, 4 núcleos	580MHz, 1 núcleo	1.4GHz, 4 núcleos	1.0GHz, 4 núcleos
512MB	1024MB	128MB	512MB	512MB
8GB	8GB	32MB	No	No
2 con expansión, 1 OTG	2	1 con expansión	1	2 con expansión, 1 OTG
HDMI	HDMI	No, monitor remoto	No, monitor remoto	miniHDMI
Si	Si	No	No	Si
Si	Si	Si	Si	Si
No	No	Si, con expansión	Si	No
Armbian	Armbian	Linux Kernel	Armbian y UbuntuCore	Armbian
micro SD	micro SD	micro SD	micro SD	micro SD
46mm x 48mm	69mm x 48mm	43mm x 26mm	40mm x 40mm	65mm x 30mm

Tabla A.2: Comparación entre diferentes computadoras embebidas.

APÉNDICE B

ANEXO 2

B.1. EJEMPLOS DE GRÁFICAS QUE REPRESENTAN A LOS EVENTOS DE CONDUCCIÓN

Las gráficas B9, B18 y B63 del ángulo de giro en el eje z (E_z) muestran la forma de una recta con pendiente positiva, porque durante la ejecución del evento no se produjo un cambio significativo en dicho eje, y por lo tanto la fusión de datos [38] toma el ruido de los sensores como entrada y ocasiona una deriva o acumulación del error [41] con el transcurso del tiempo.

Categoría: Velocidad

Evento: Frenar

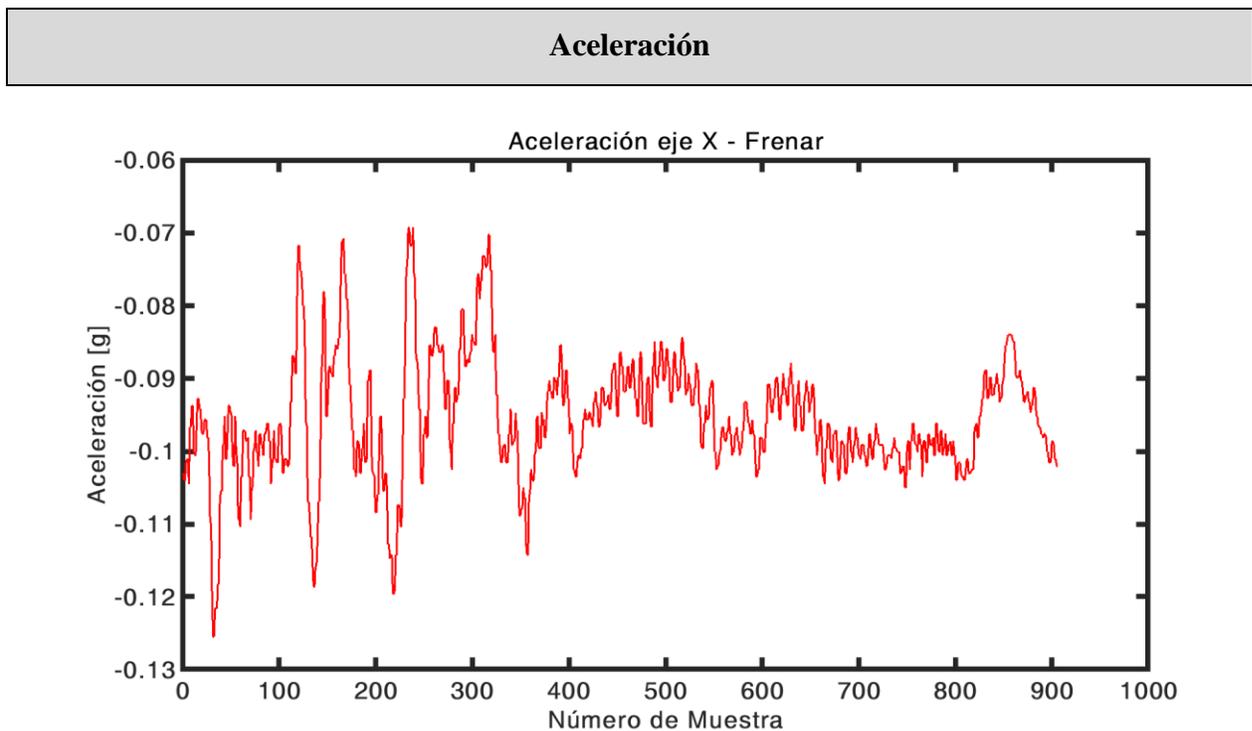


Figura B.1: Gráfica de la aceleración en el eje x (A_x) para el evento Frenar.

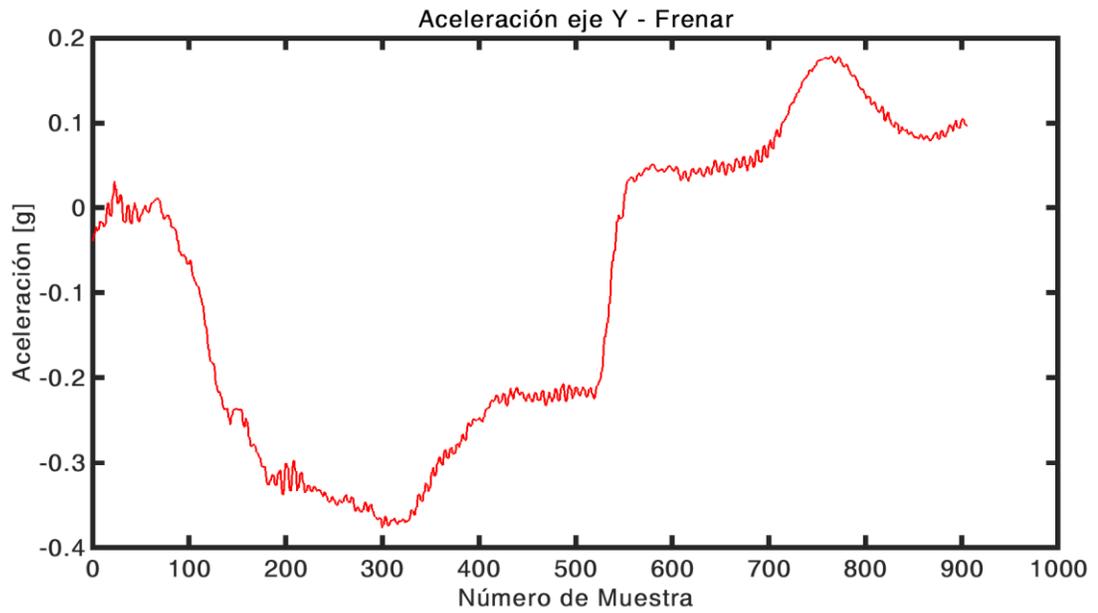


Figura B.2: Gráfica de la aceleración en el eje y (A_y) para el evento Frenar.

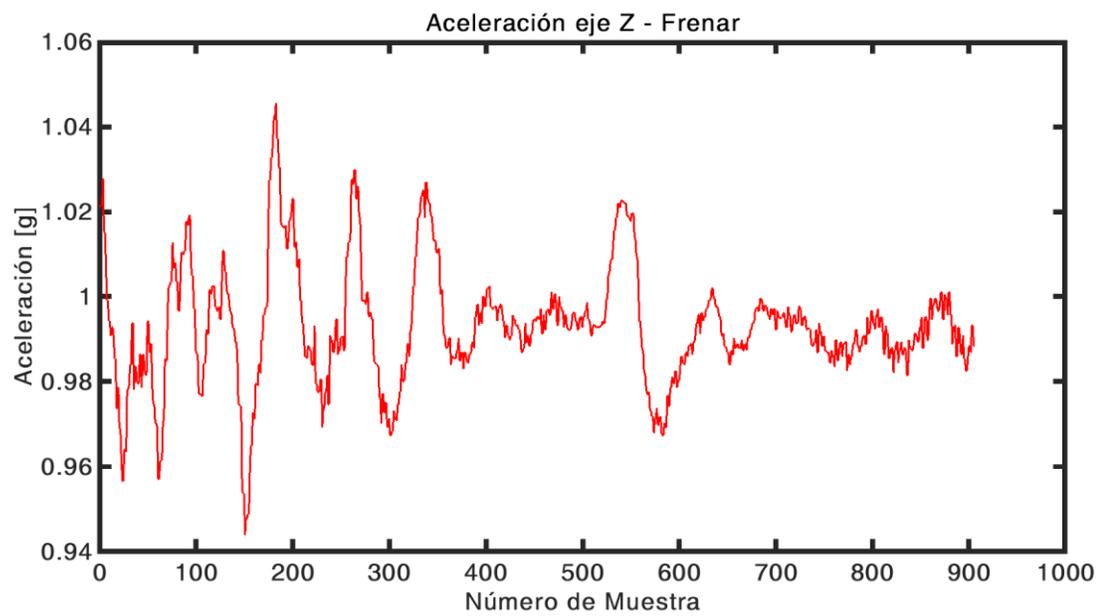


Figura B.3: Gráfica de la aceleración en el eje z (A_z) para el evento Frenar.

Velocidad angular

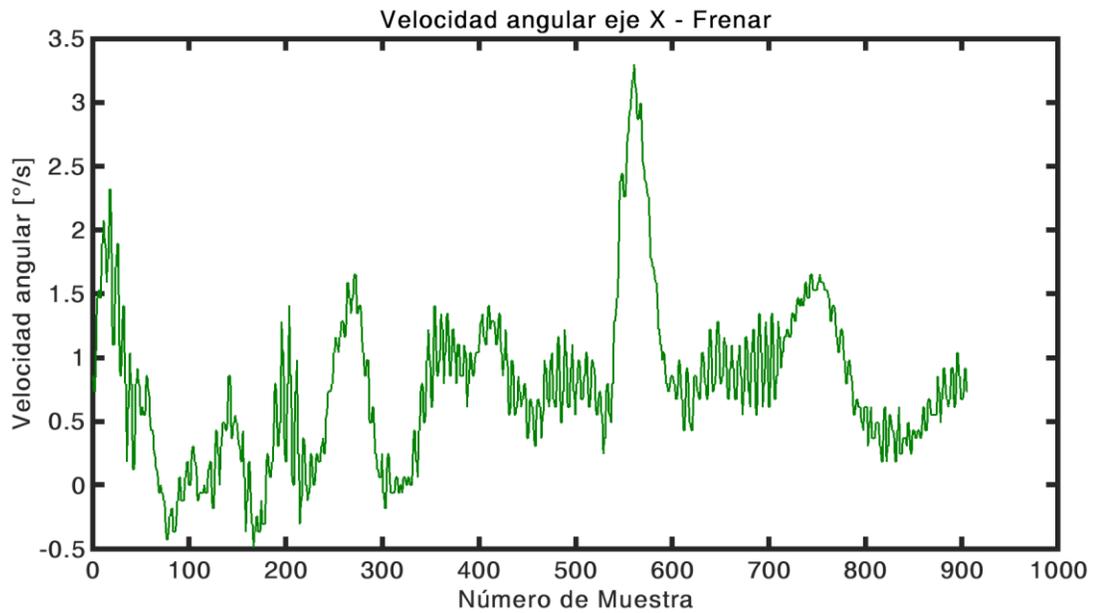


Figura B.4: Gráfica de la velocidad angular en el eje x (G_x) para el evento Frenar.

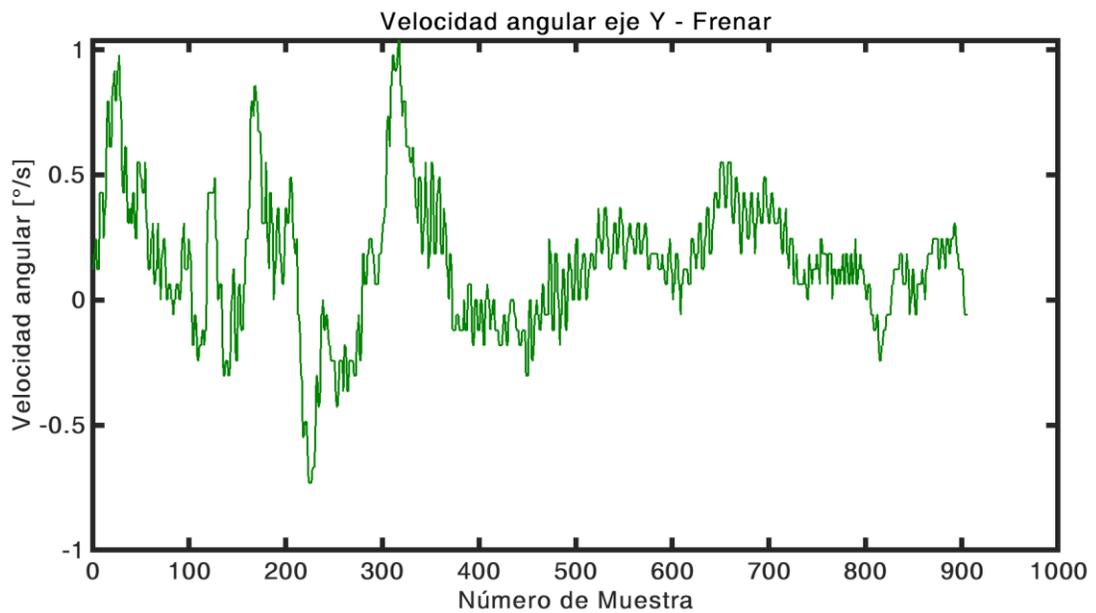


Figura B.5: Gráfica de la velocidad angular en el eje y (G_y) para el evento Frenar.

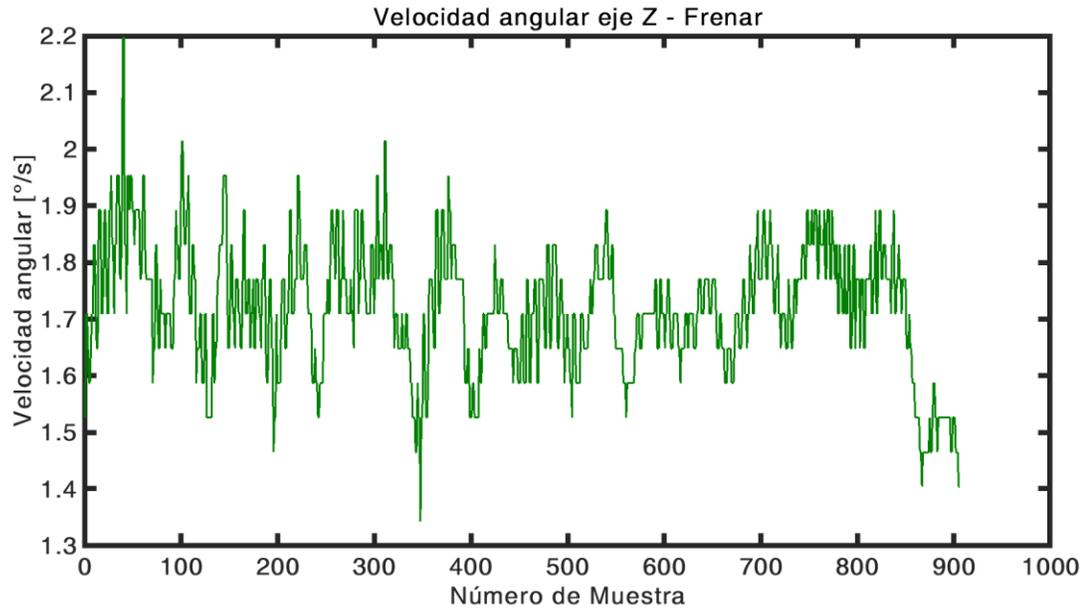


Figura B.6: Gráfica de la velocidad angular en el eje z (G_z) para el evento Frenar.

Ángulo de giro

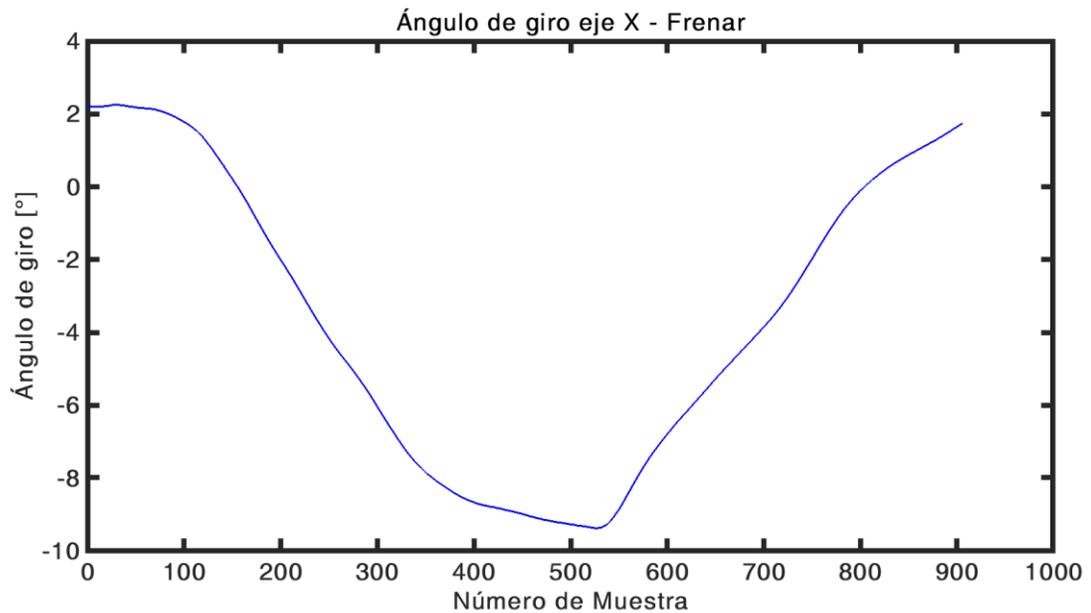


Figura B.7: Gráfica del ángulo de giro en el eje x (E_x) para el evento Frenar, relativo a la dirección donde se detectó el inicio del evento.

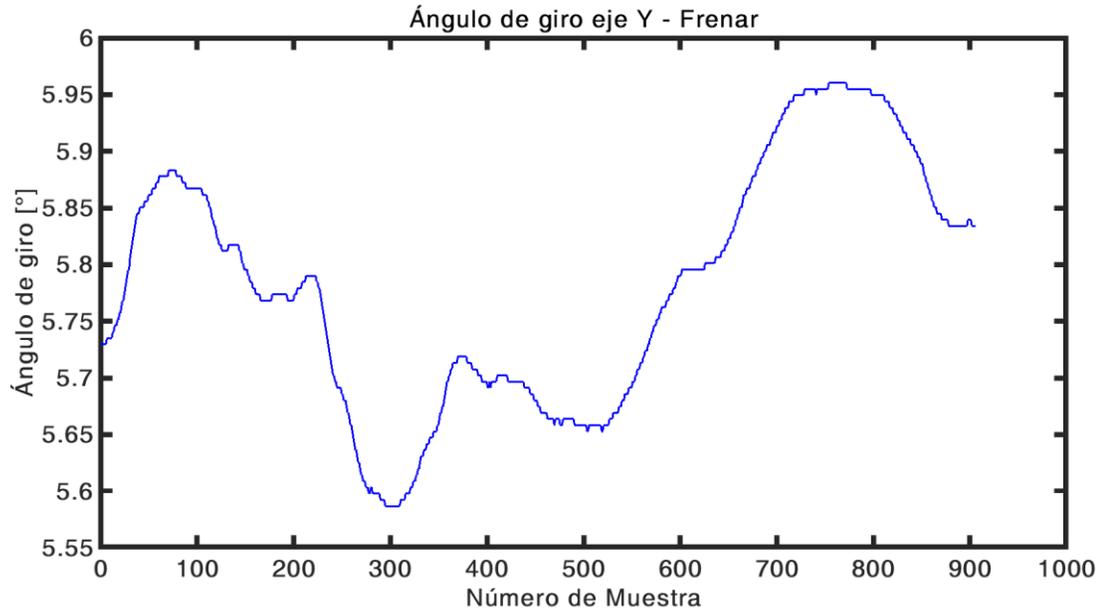


Figura B.8: Gráfica del ángulo de giro en el eje y (E_y) para el evento Frenar, relativo a la dirección donde se detectó el inicio del evento.

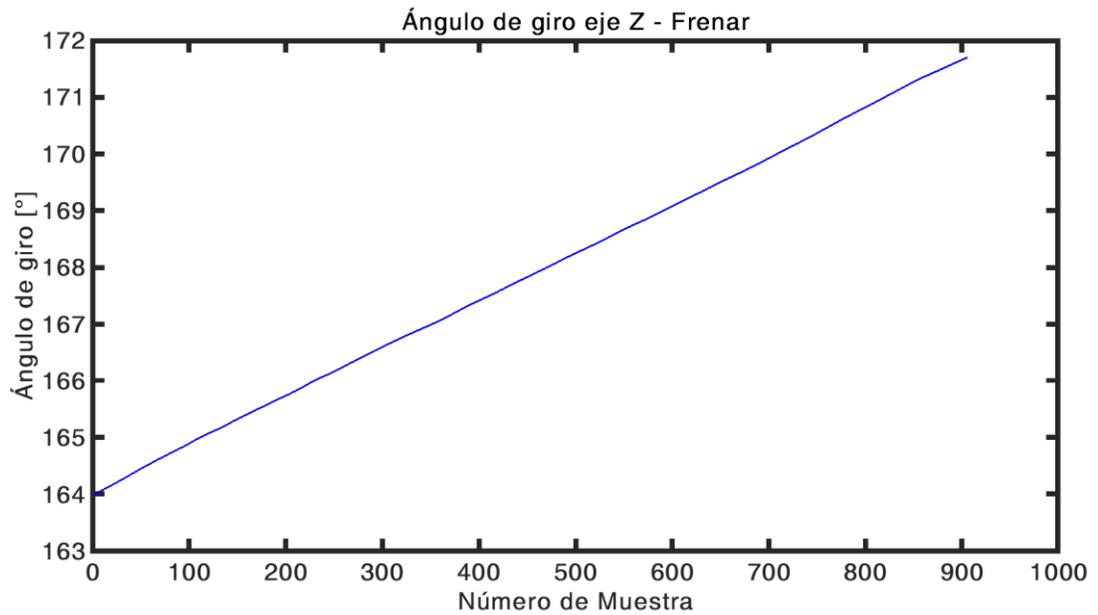


Figura B.9: Gráfica del ángulo de giro en el eje z (E_z) para el evento Frenar, relativo a la dirección donde se detectó el inicio del evento.

Categoría: Velocidad

Evento: Acelerar

Aceleración

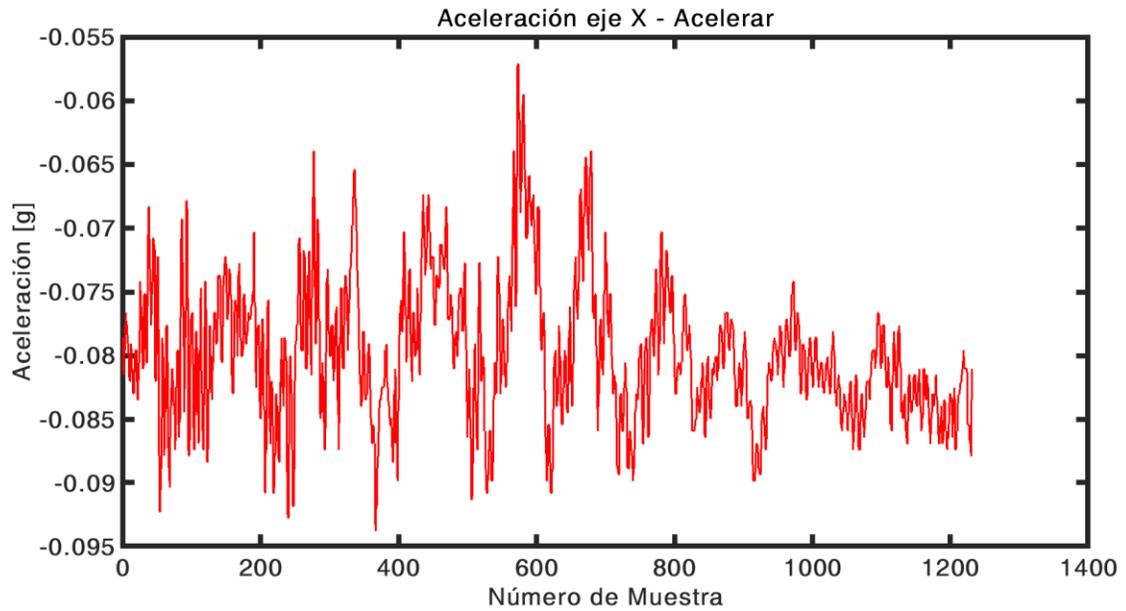


Figura B.10: Gráfica de la aceleración en el eje x (A_x) para el evento Acelerar.

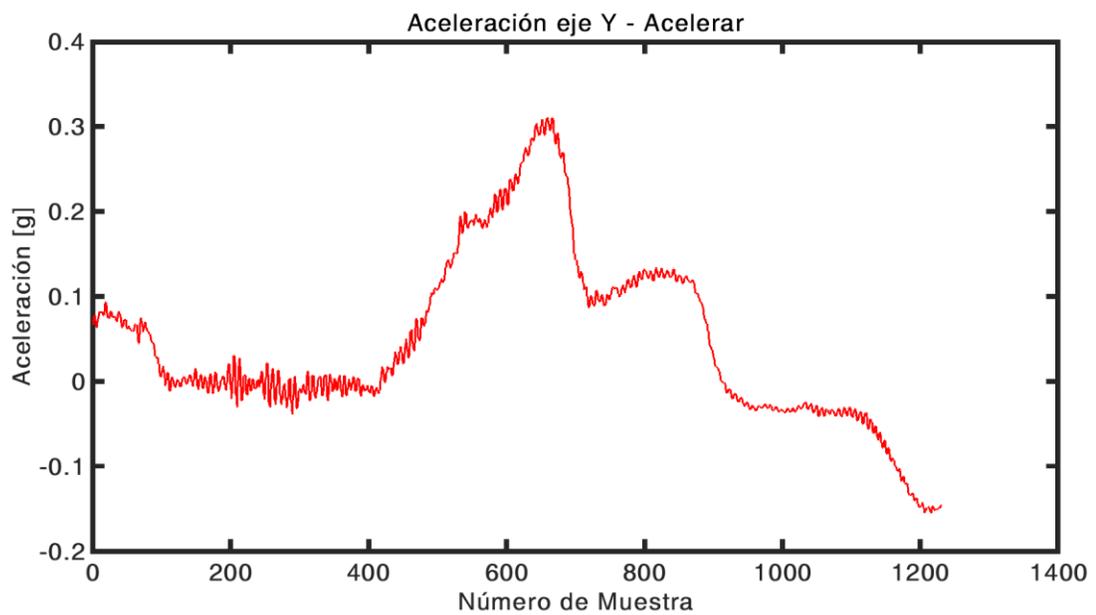


Figura B.11: Gráfica de la aceleración en el eje y (A_y) para el evento Acelerar.

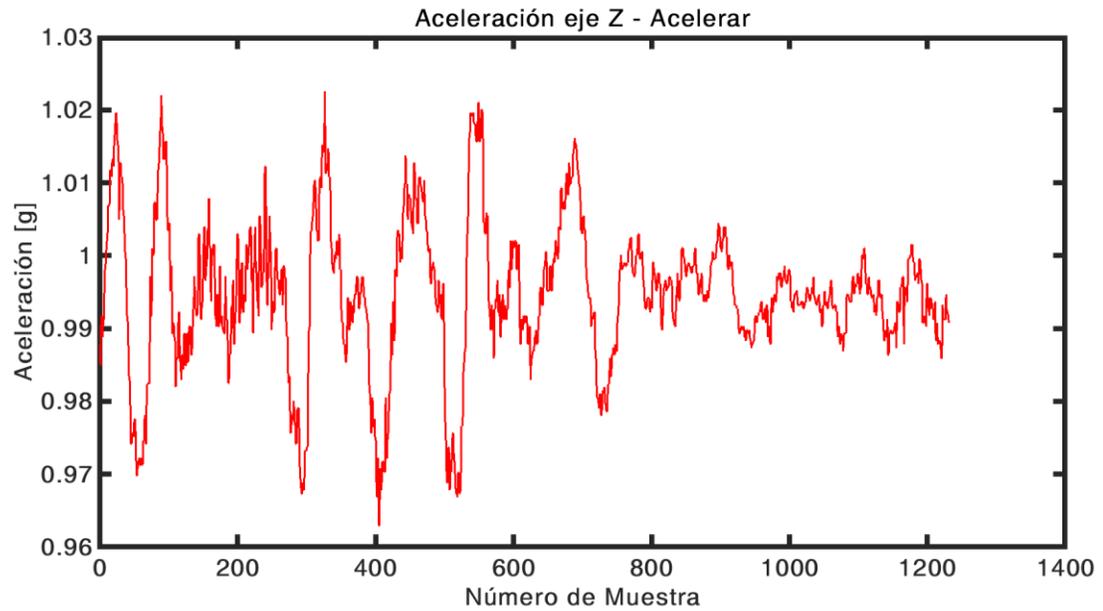


Figura B.12: Gráfica de la aceleración en el eje z (A_z) para el evento Acelerar.

Velocidad angular

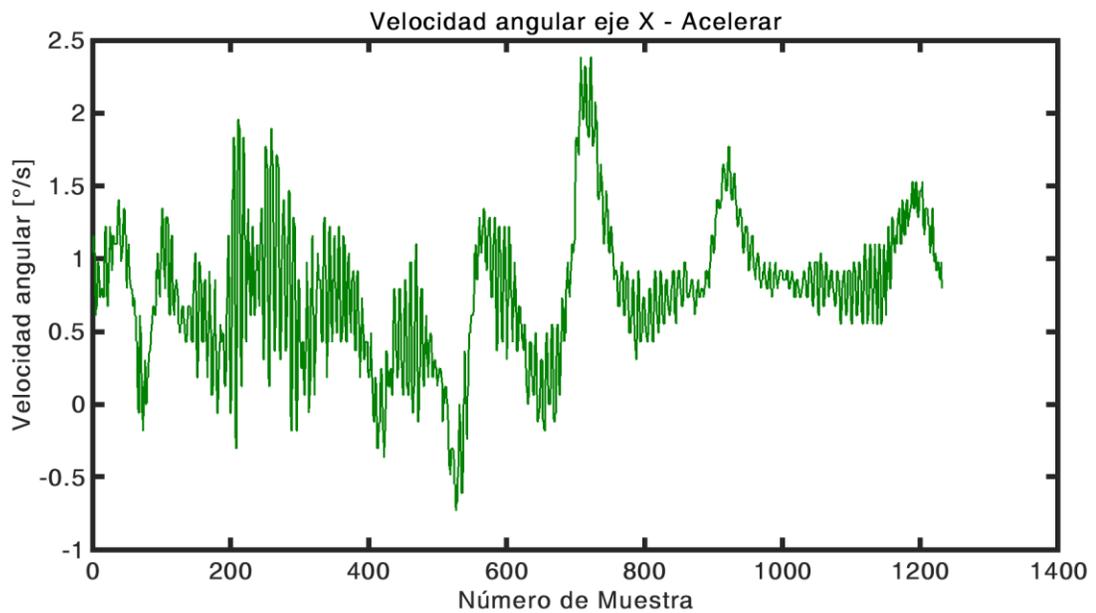


Figura B.13: Gráfica de la velocidad angular en el eje x (G_x) para el evento Acelerar.

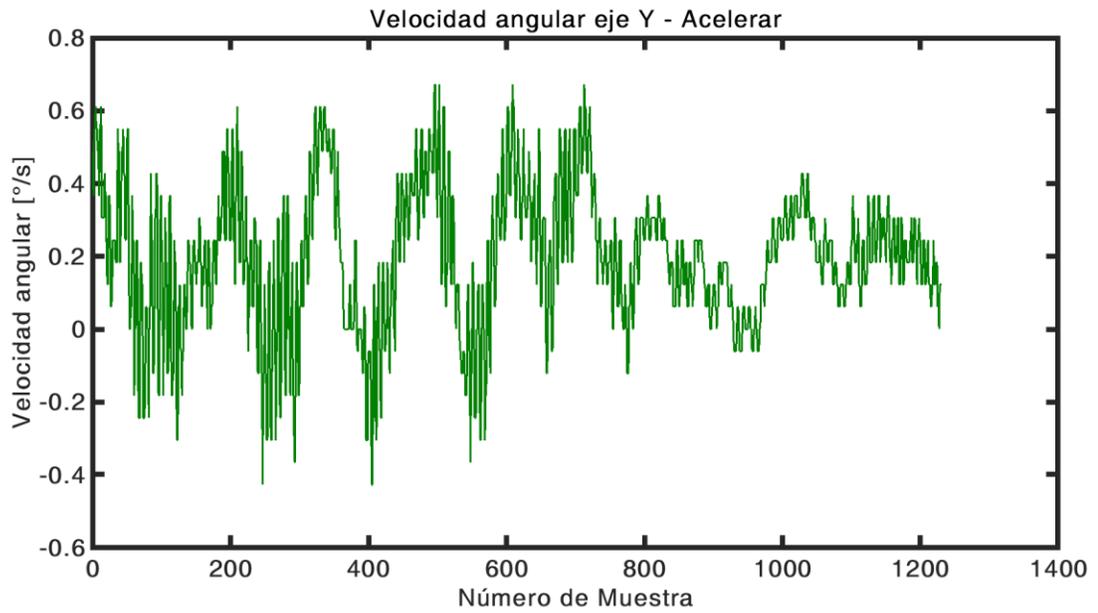


Figura B.14: Gráfica de la velocidad angular en el eje y (G_y) para el evento Acelerar.

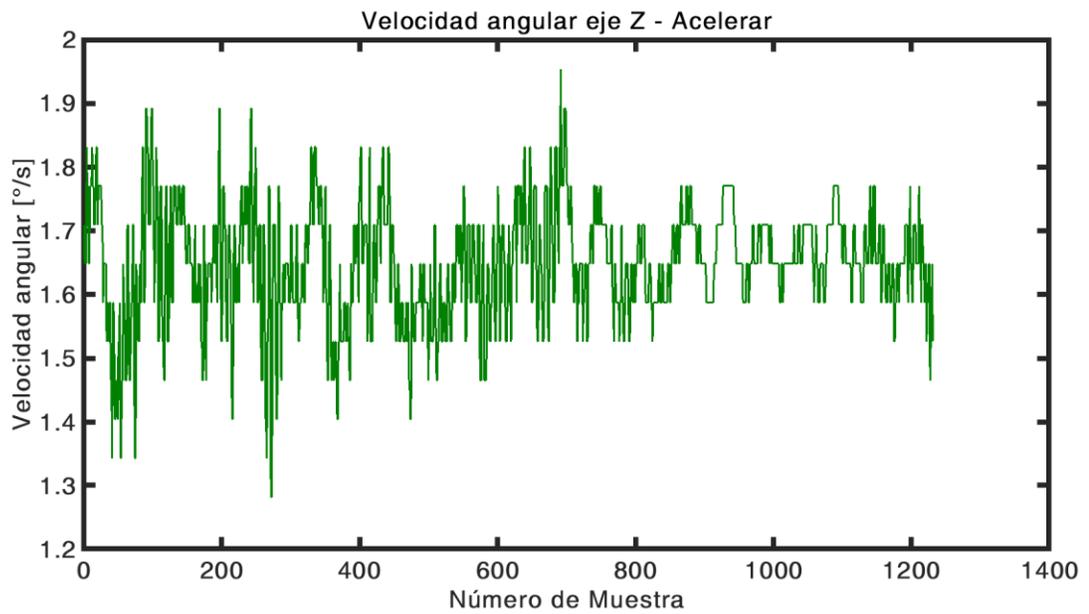


Figura B.15: Gráfica de la velocidad angular en el eje z (G_z) para el evento Acelerar.

Ángulo de giro

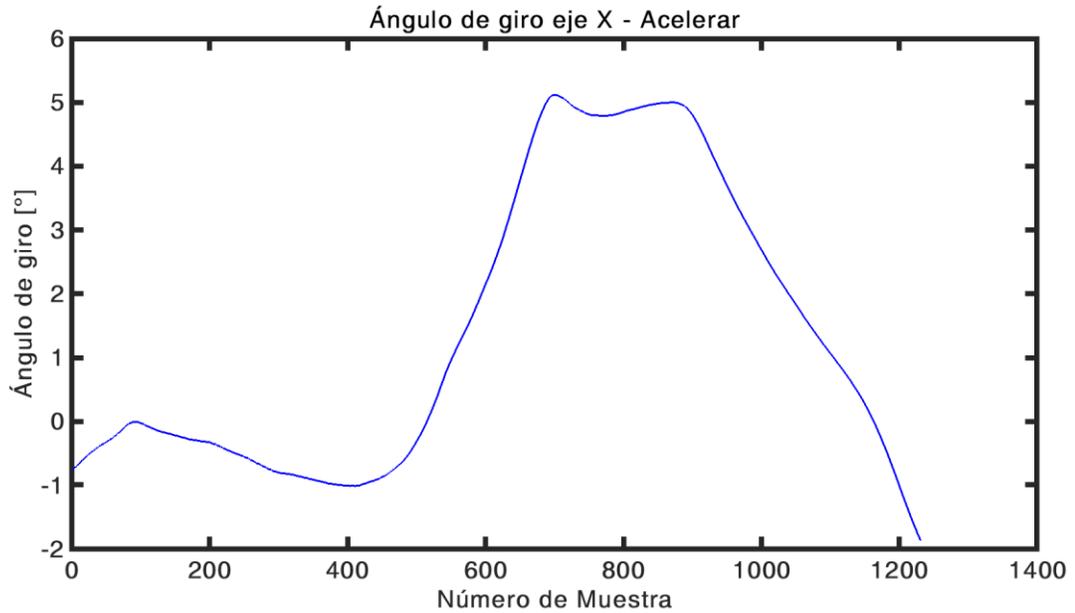


Figura B.16: Gráfica del ángulo de giro en el eje x (E_x) para el evento Acelerar, relativo a la dirección donde se detectó el inicio del evento.

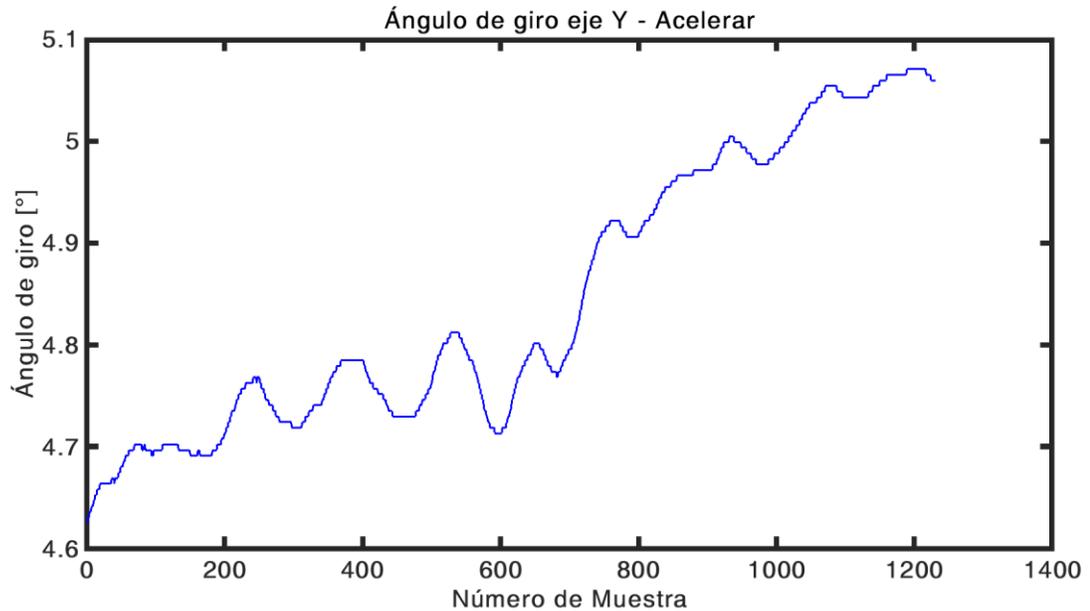


Figura B.17: Gráfica del ángulo de giro en el eje y (E_y) para el evento Acelerar, relativo a la dirección donde se detectó el inicio del evento.

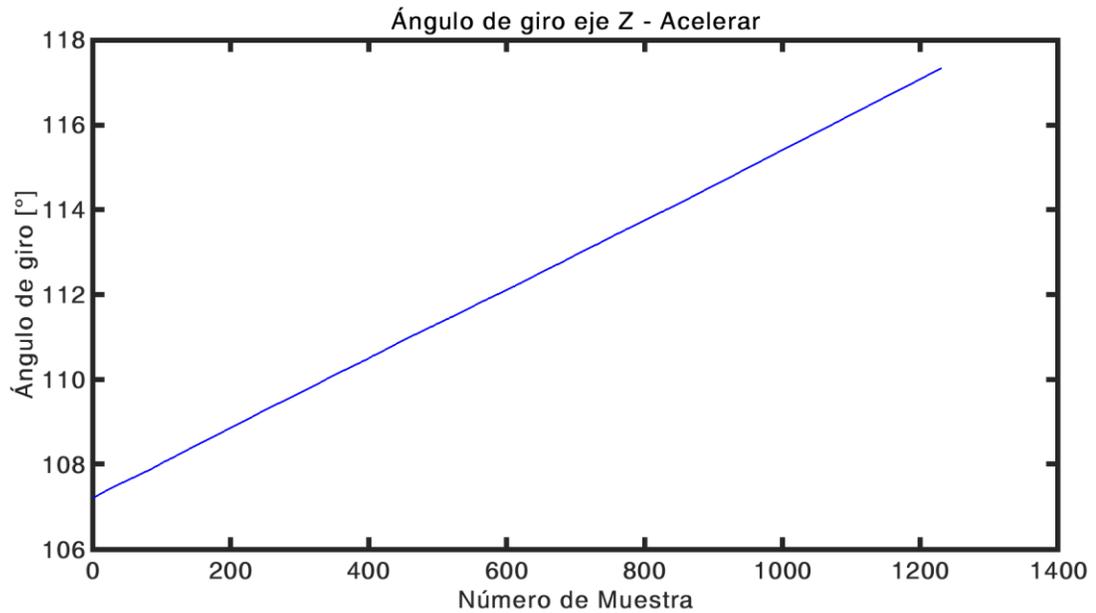


Figura B.18: Gráfica del ángulo de giro en el eje z (E_z) para el evento Acelerar, relativo a la dirección donde se detectó el inicio del evento.

Categoría: Vueltas

Evento: Vuelta a la izquierda

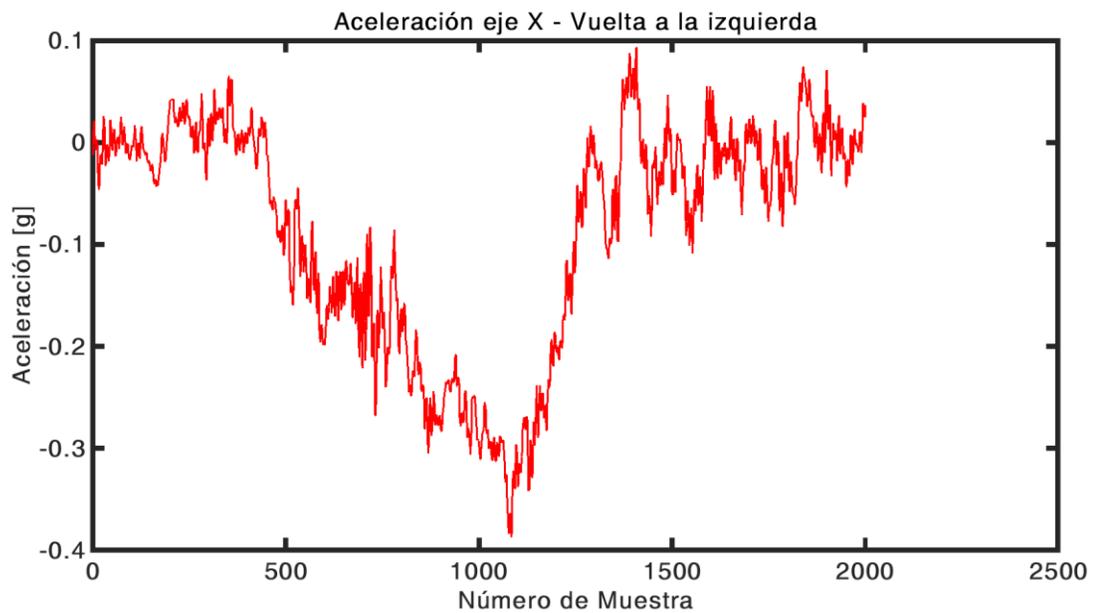


Figura B.19: Gráfica de la aceleración en el eje x (A_x) para el evento Vuelta a la izquierda.

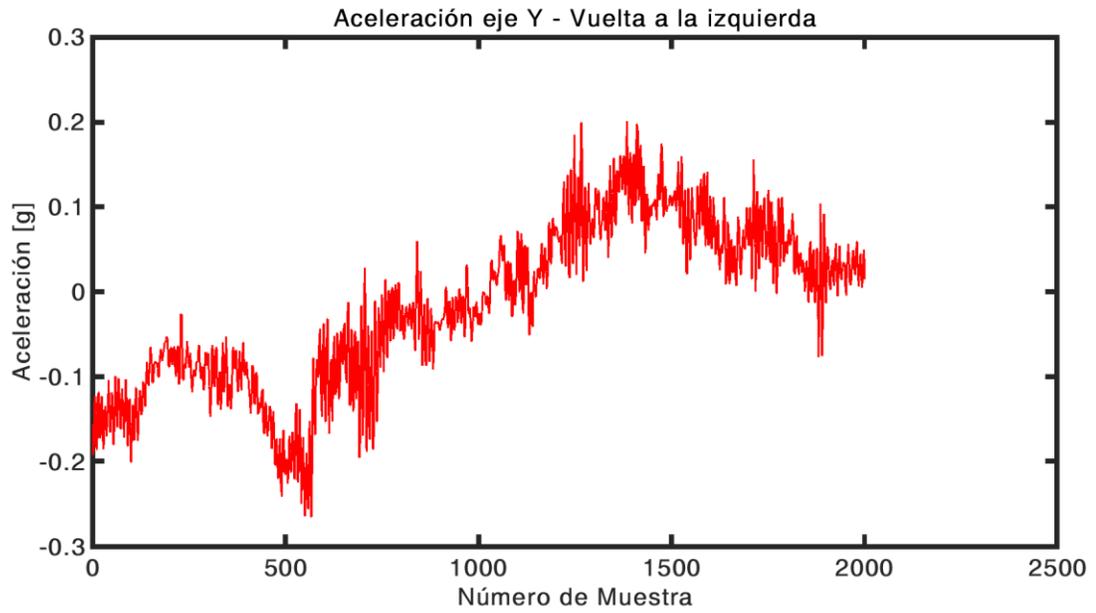


Figura B.20: Gráfica de la aceleración en el eje y (A_y) para el evento Vuelta a la izquierda.

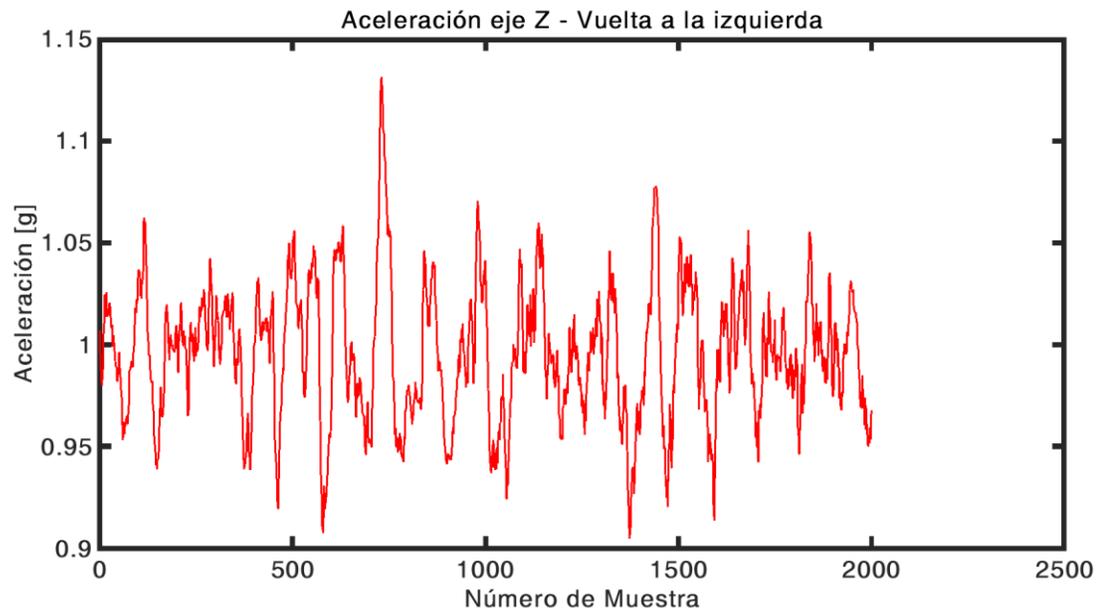


Figura B.21: Gráfica de la aceleración en el eje z (A_z) para el evento Vuelta a la izquierda.

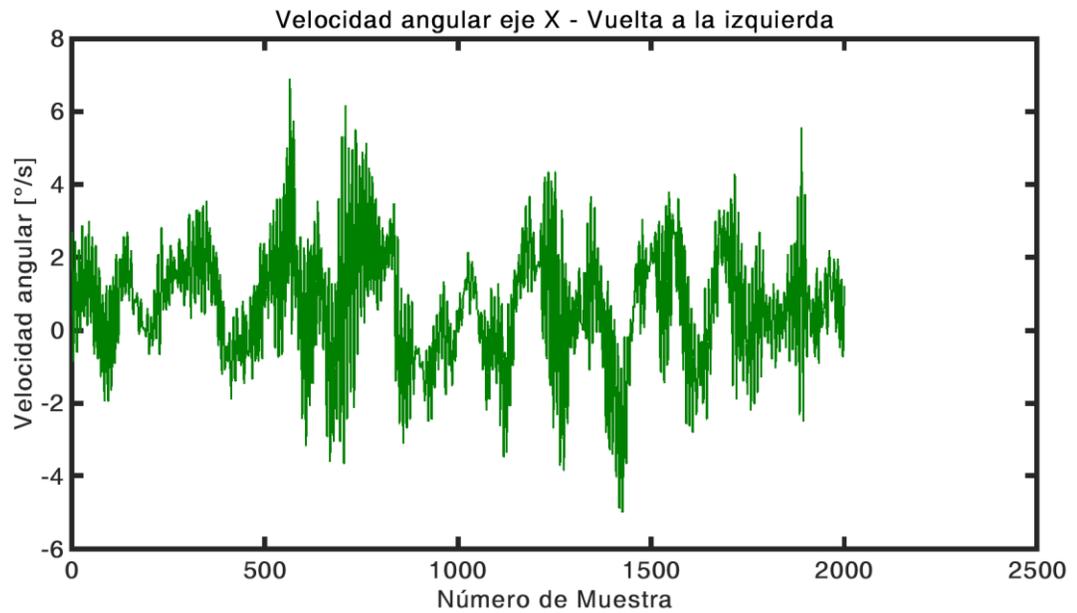
Velocidad angular

Figura B.22: Gráfica de la velocidad angular en el eje x (G_x) para el evento Vuelta a la izquierda.

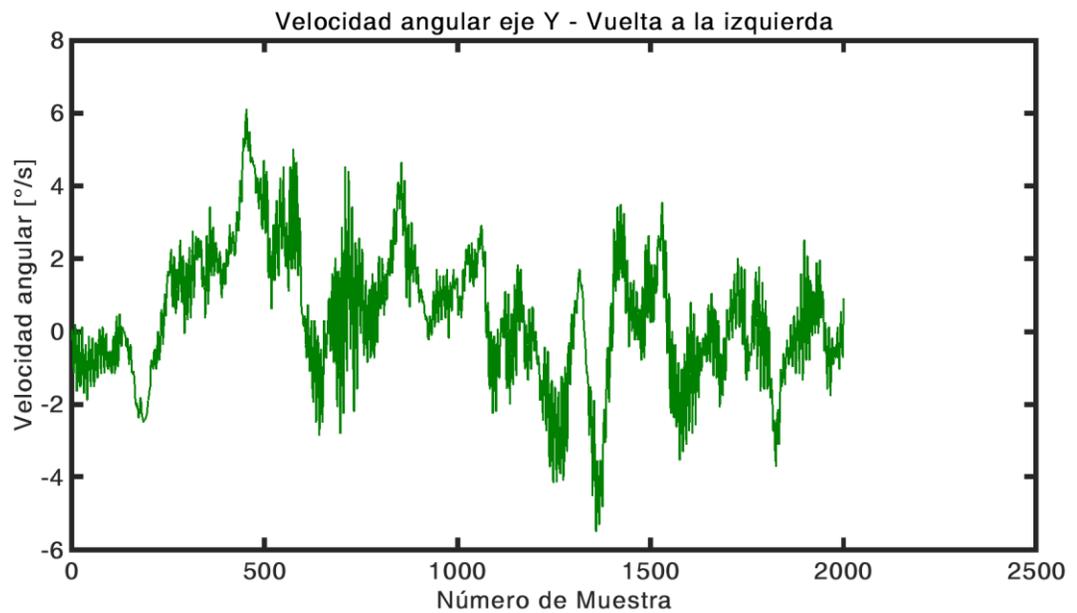


Figura B.23: Gráfica de la velocidad angular en el eje y (G_y) para el evento Vuelta a la izquierda.

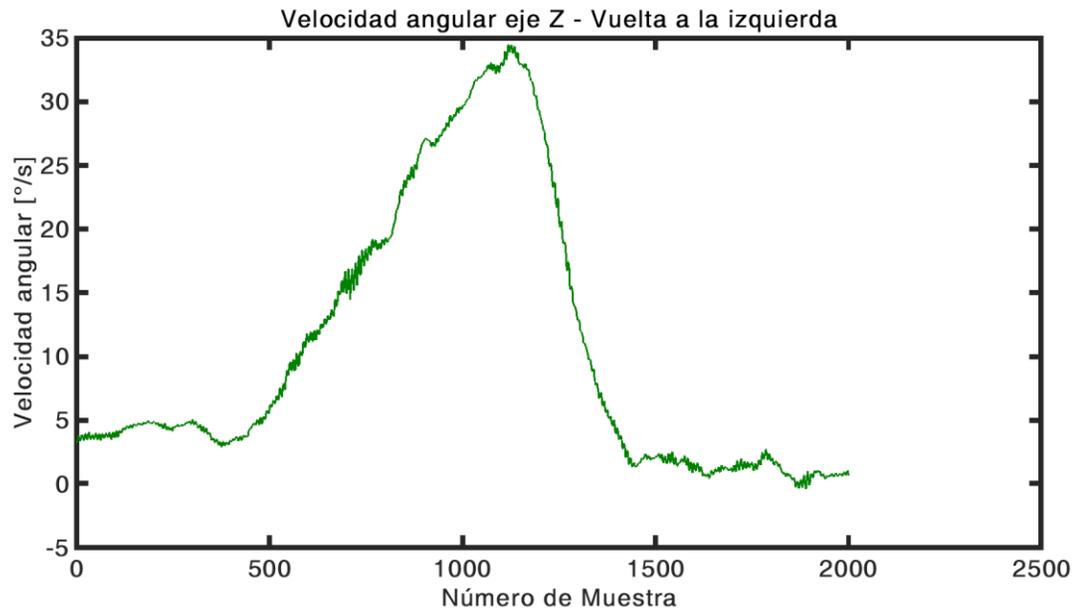


Figura B.24: Gráfica de la velocidad angular en el eje z (G_z) para el evento Vuelta a la izquierda.

Ángulo de giro

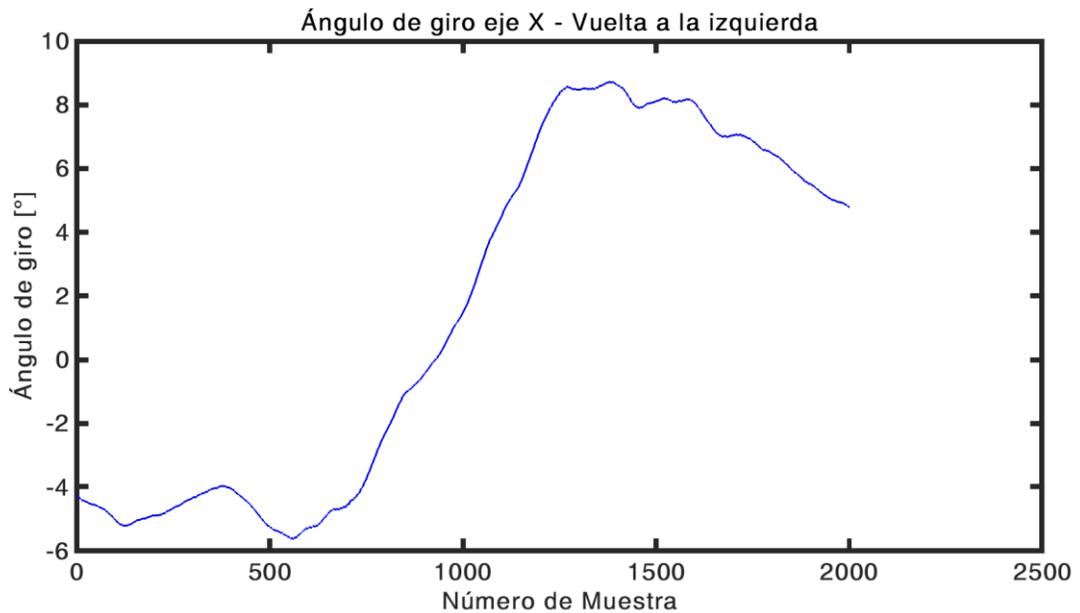


Figura B.25: Gráfica del ángulo de giro en el eje x (E_x) para el evento Vuelta a la izquierda, relativo a la dirección donde se detectó el inicio del evento.

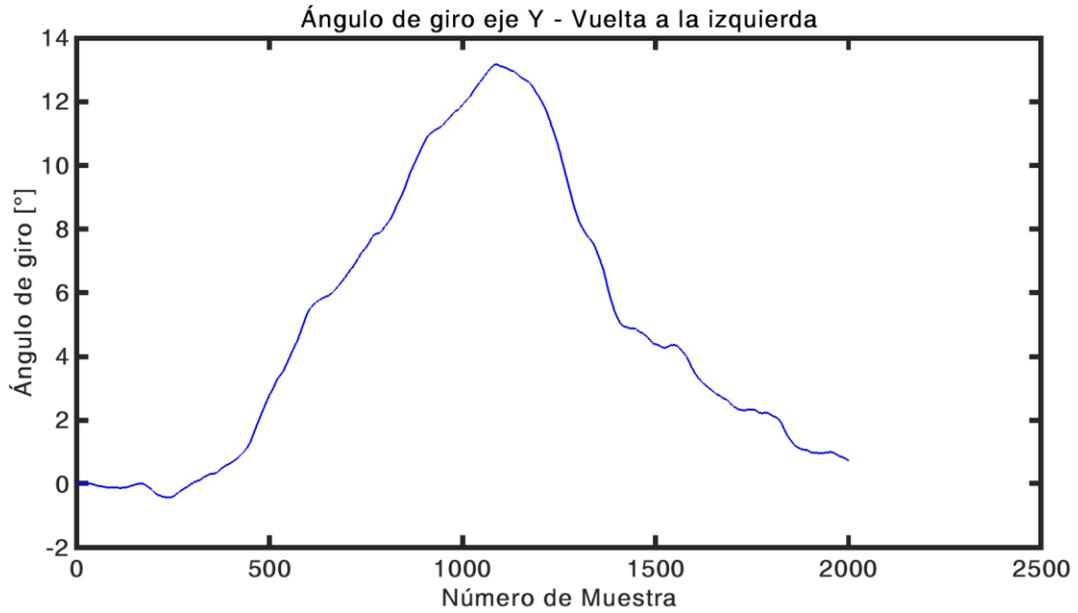


Figura B.26: Gráfica del ángulo de giro en el eje y (E_y) para el evento Vuelta a la izquierda, relativo a la dirección donde se detectó el inicio del evento.

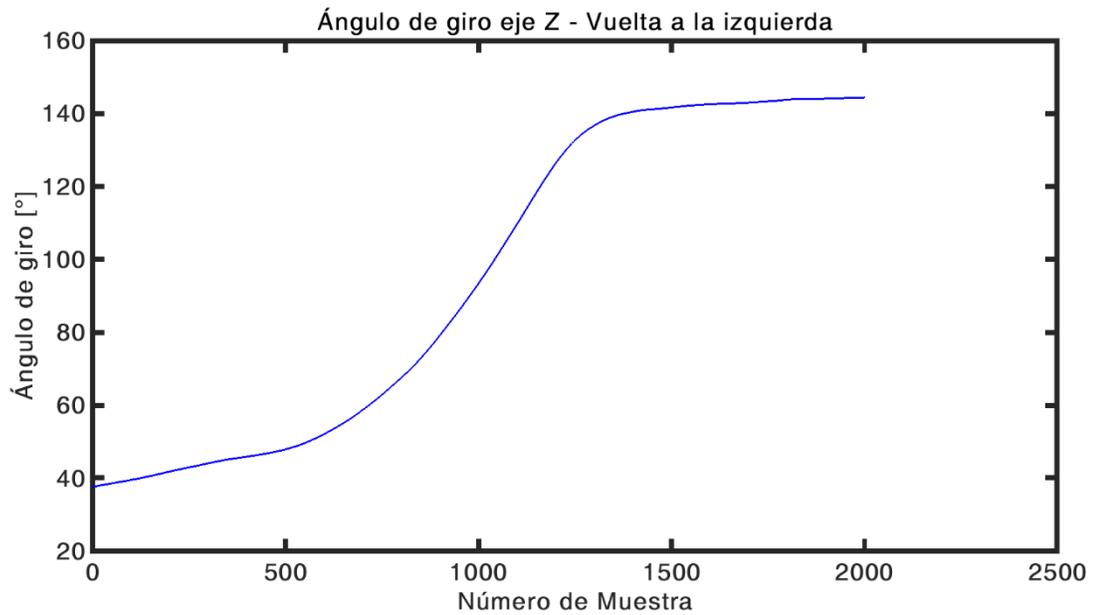


Figura B.27: Gráfica del ángulo de giro en el eje z (E_z) para el evento Vuelta a la izquierda, relativo a la dirección donde se detectó el inicio del evento.

Categoría: Vueltas

Evento: Vuelta a la derecha

Aceleración

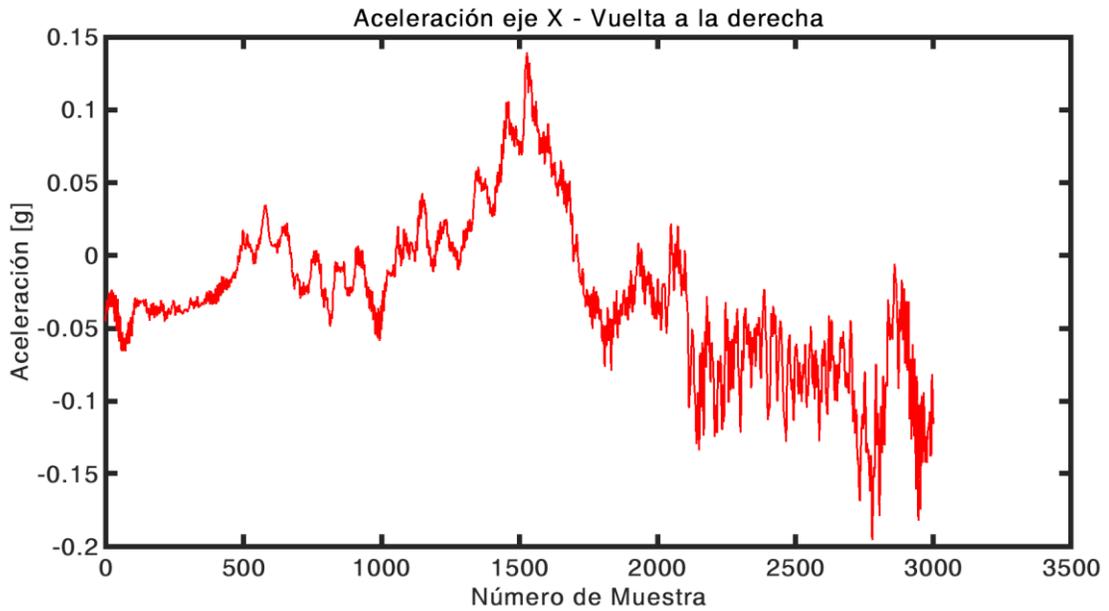


Figura B.28: Gráfica de la aceleración en el eje x (A_x) para el evento Vuelta a la derecha.

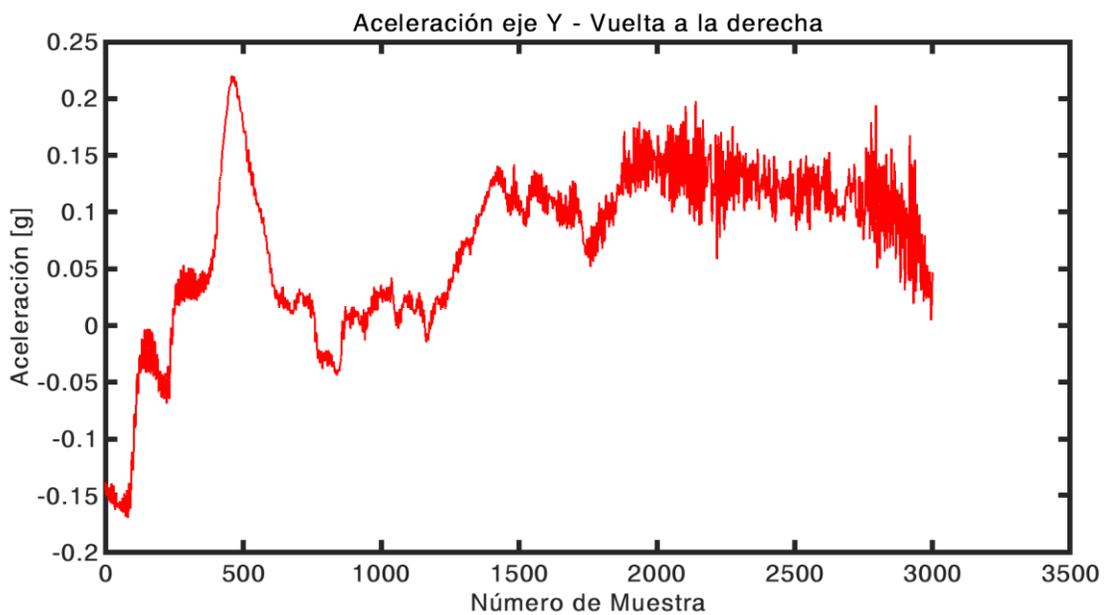


Figura B.29: Gráfica de la aceleración en el eje y (A_y) para el evento Vuelta a la derecha.

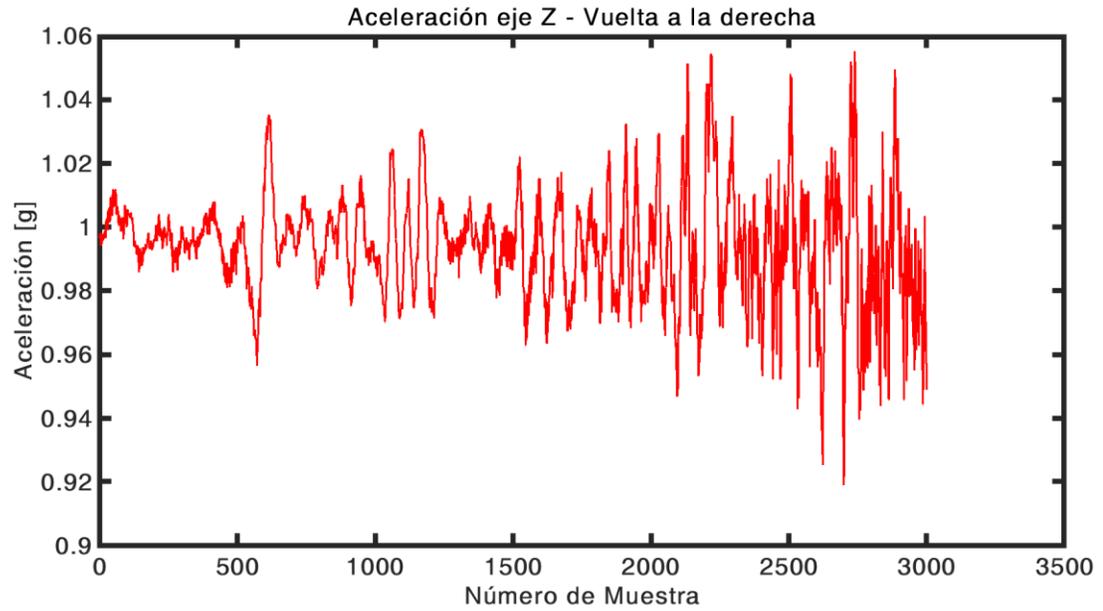


Figura B.30: Gráfica de la aceleración en el eje z (A_z) para el evento Vuelta a la derecha.

Velocidad angular

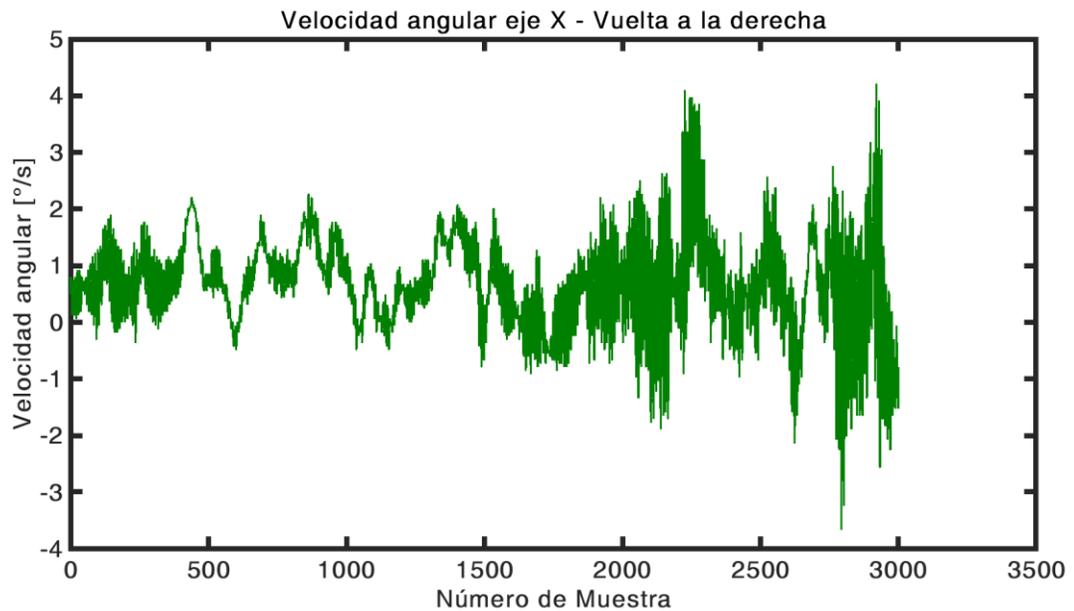


Figura B.31: Gráfica de la velocidad angular en el eje x (G_x) para el evento Vuelta a la derecha.

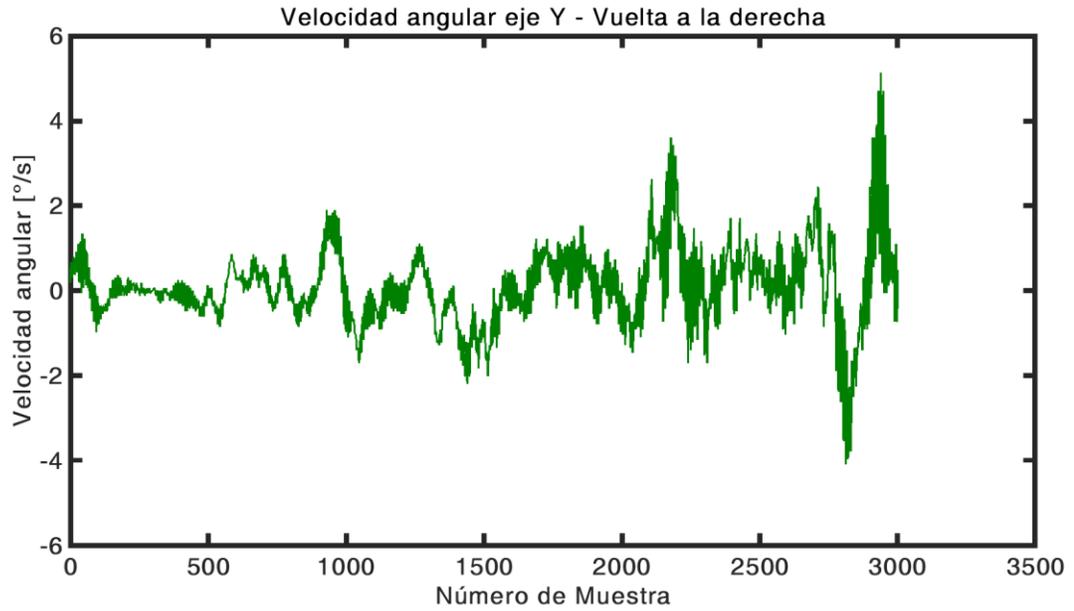


Figura B.32: Gráfica de la velocidad angular en el eje y (G_y) para el evento Vuelta a la derecha.

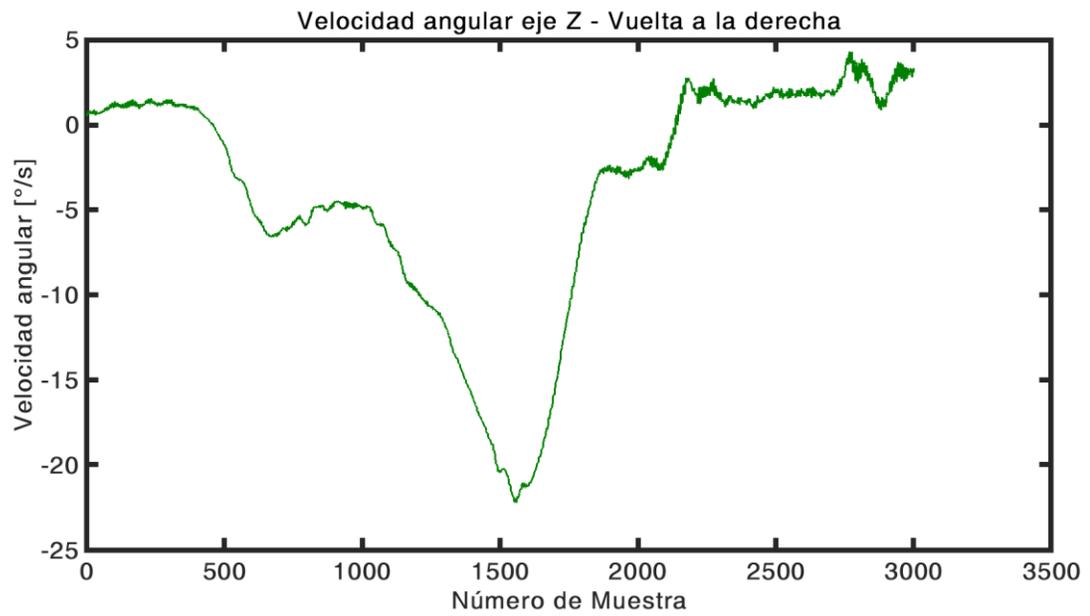


Figura B.33: Gráfica de la velocidad angular en el eje z (G_z) para el evento Vuelta a la derecha.

Ángulo de giro

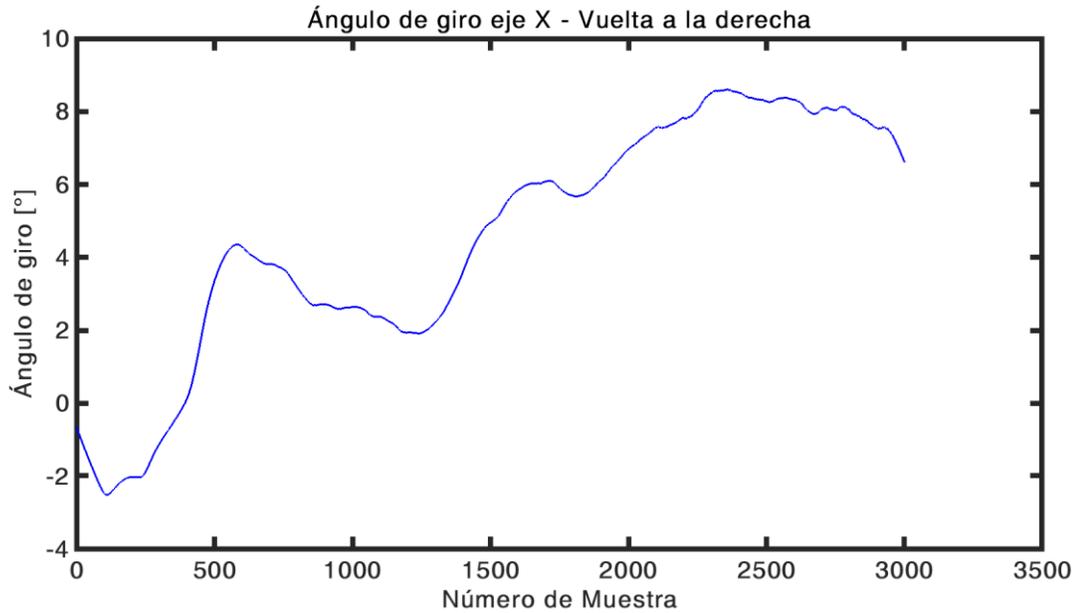


Figura B.34: Gráfica del ángulo de giro en el eje x (E_x) para el evento Vuelta a la derecha, relativo a la dirección donde se detectó el inicio del evento.

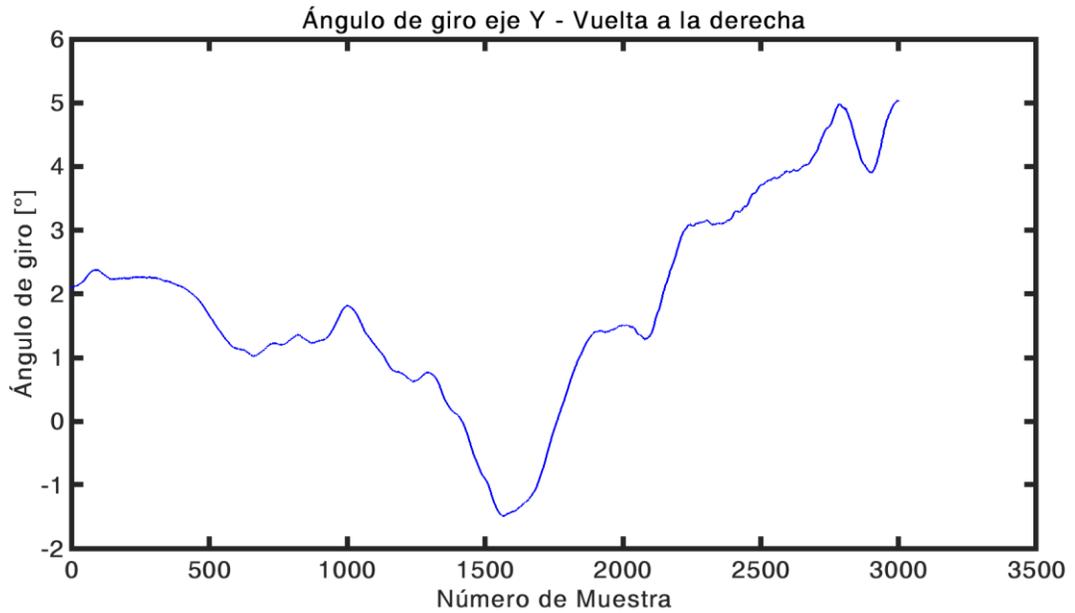


Figura B.35: Gráfica del ángulo de giro en el eje y (E_y) para el evento Vuelta a la derecha, relativo a la dirección donde se detectó el inicio del evento.

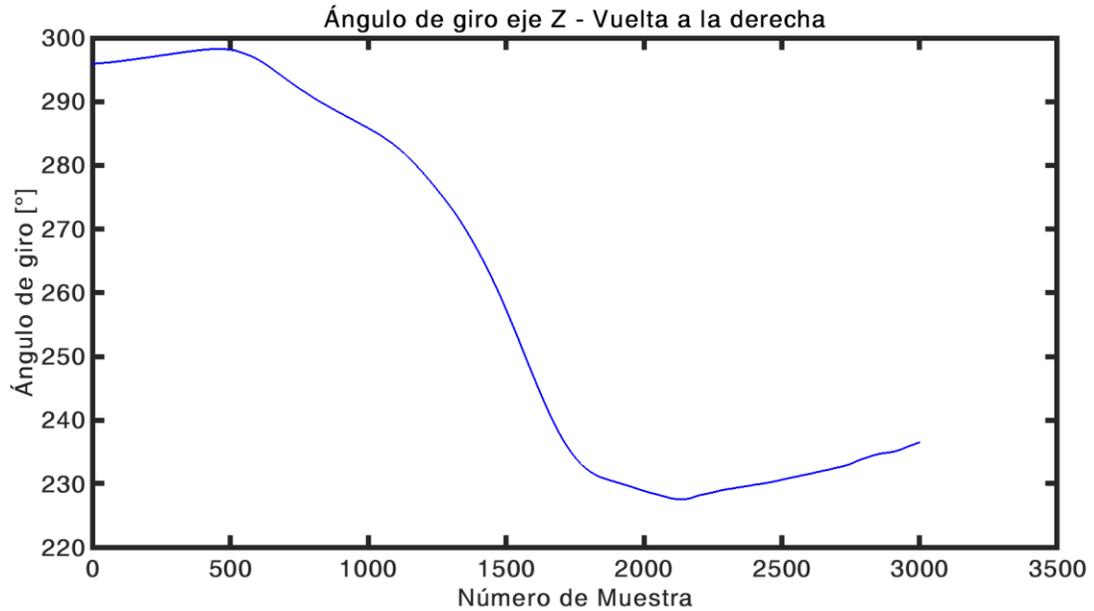


Figura B.36: Gráfica del ángulo de giro en el eje z (E_z) para el evento Vuelta a la derecha, relativo a la dirección donde se detectó el inicio del evento.

Categoría: Vueltas

Evento: Vuelta a la izquierda en U

Aceleración

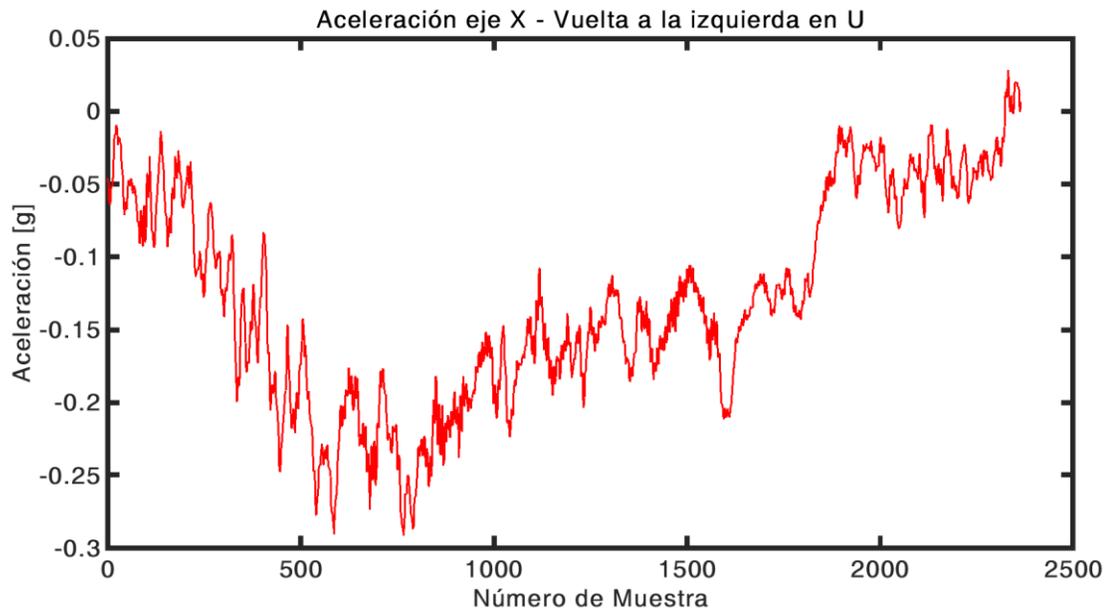


Figura B.37: Gráfica de la aceleración en el eje x (A_x) para el evento Vuelta a la izquierda en U.

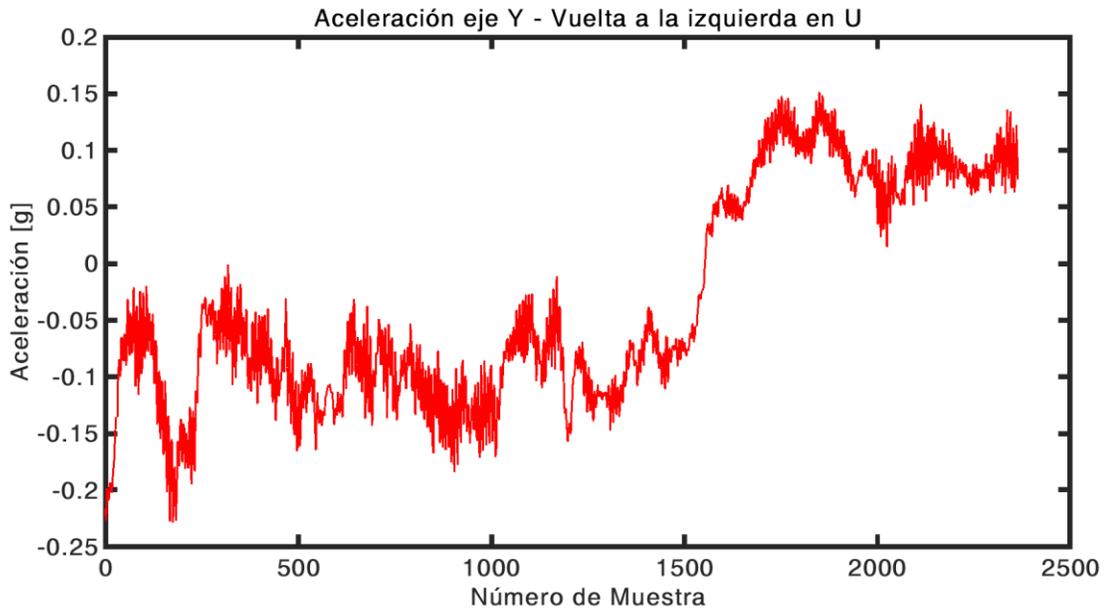


Figura B.38: Gráfica de la aceleración en el eje y (A_y) para el evento Vuelta a la izquierda en U.

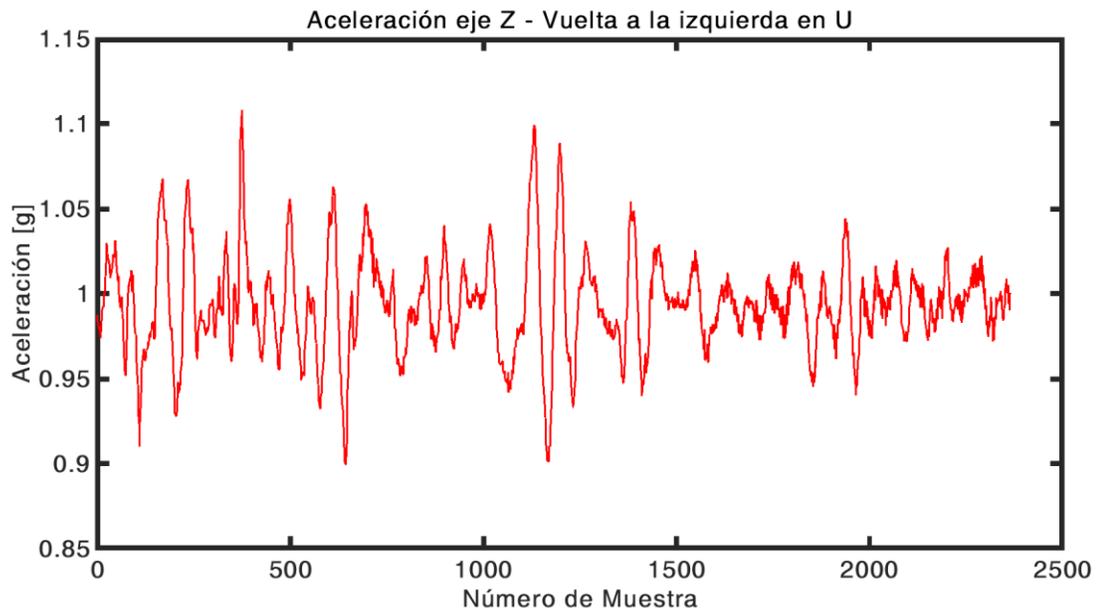
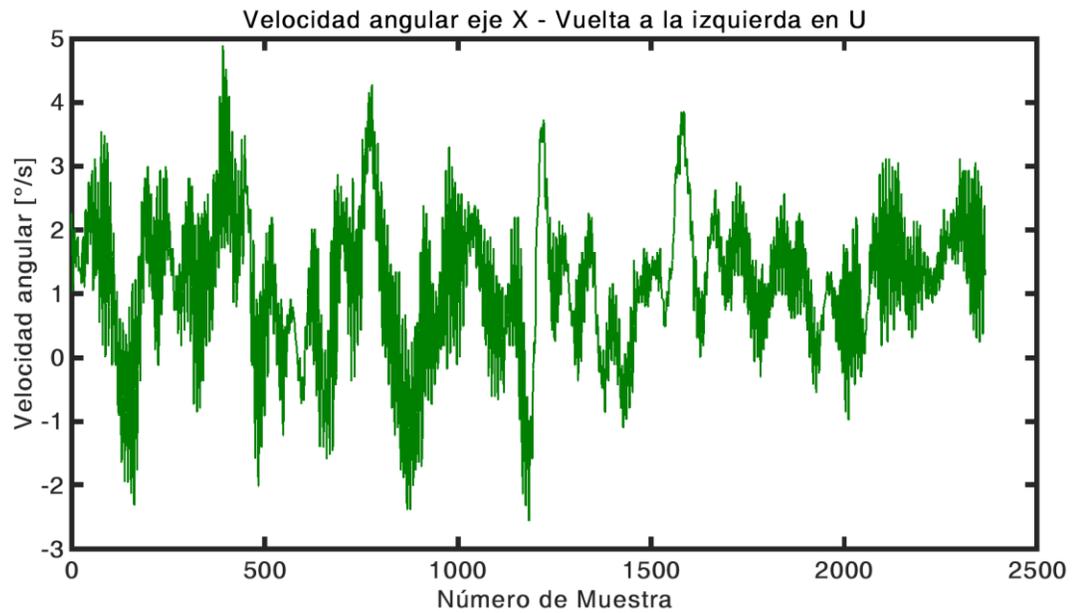
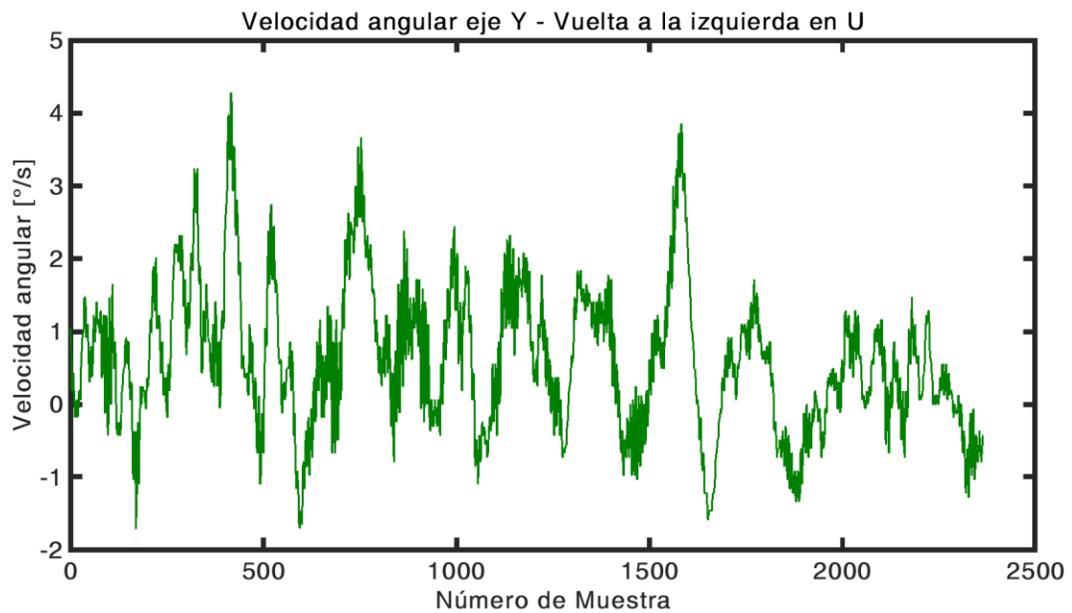


Figura B.39: Gráfica de la aceleración en el eje z (A_z) para el evento Vuelta a la izquierda en U.

Velocidad angularFigura B.40: Gráfica de la velocidad angular en el eje x (G_x) para el evento Vuelta a la izquierda en U.Figura B.41: Gráfica de la velocidad angular en el eje y (G_y) para el evento Vuelta a la izquierda en U.

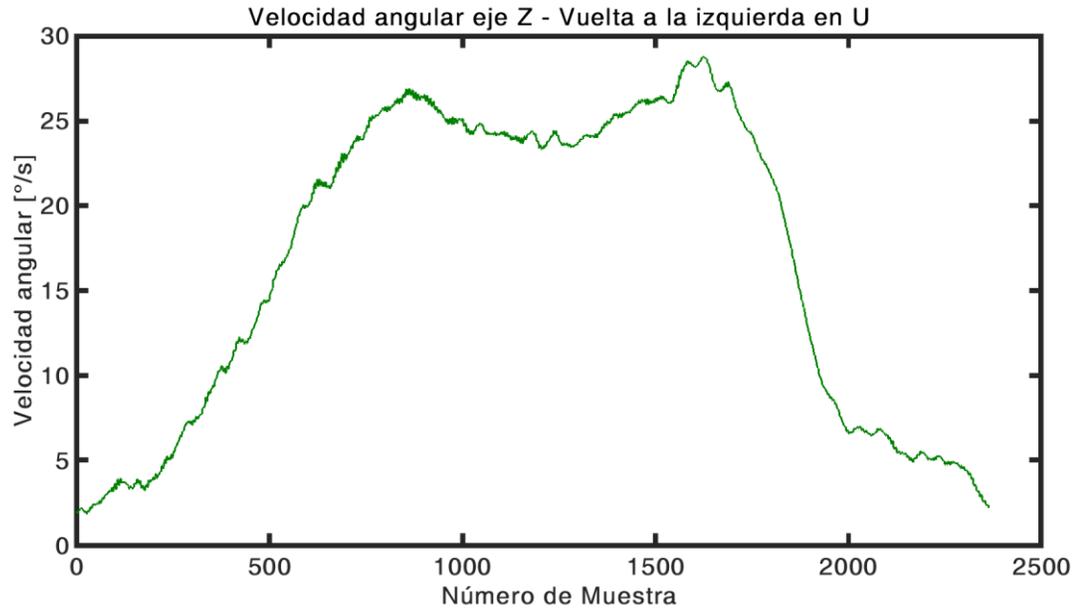


Figura B.42: Gráfica de la velocidad angular en el eje z (G_z) para el evento Vuelta a la izquierda en U.

Ángulo de giro

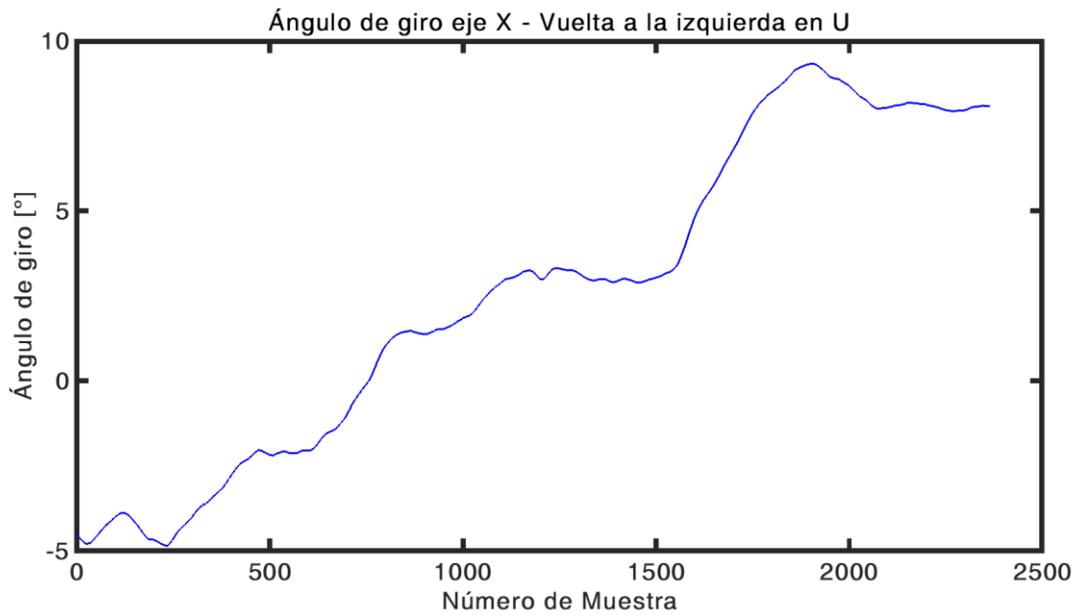


Figura B.43: Gráfica del ángulo de giro en el eje x (E_x) para el evento Vuelta a la izquierda en U, relativo a la dirección donde se detectó el inicio del evento.

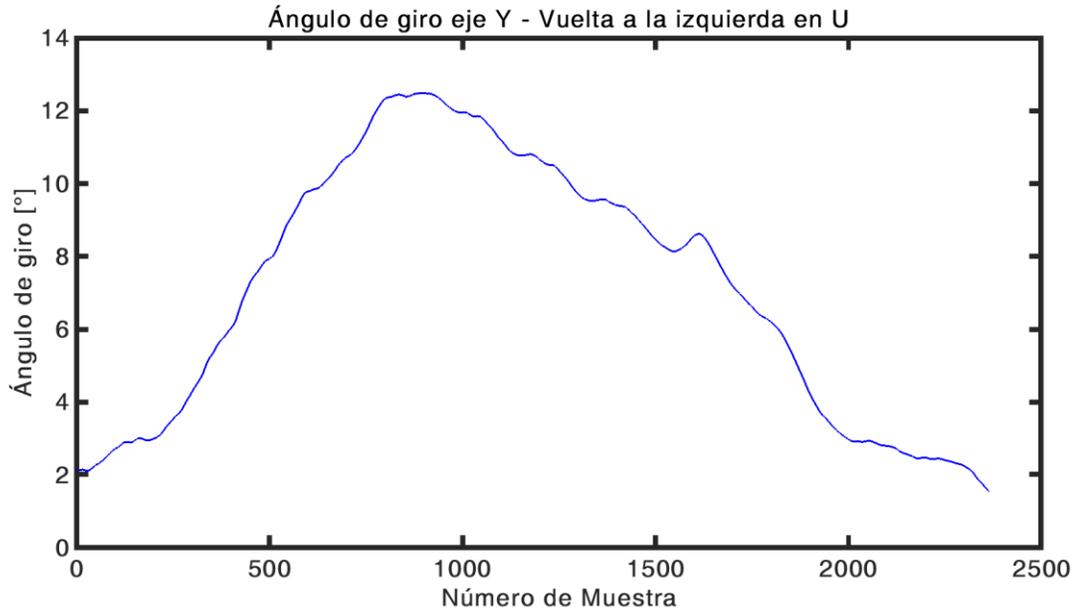


Figura B.44: Gráfica del ángulo de giro en el eje y (E_y) para el evento Vuelta a la izquierda en U, relativo a la dirección donde se detectó el inicio del evento.



Figura B.45: Gráfica del ángulo de giro en el eje z (E_z) para el evento Vuelta a la izquierda en U, relativo a la dirección donde se detectó el inicio del evento.

Categoría: Vueltas

Evento: Vuelta a la derecha en U

Aceleración

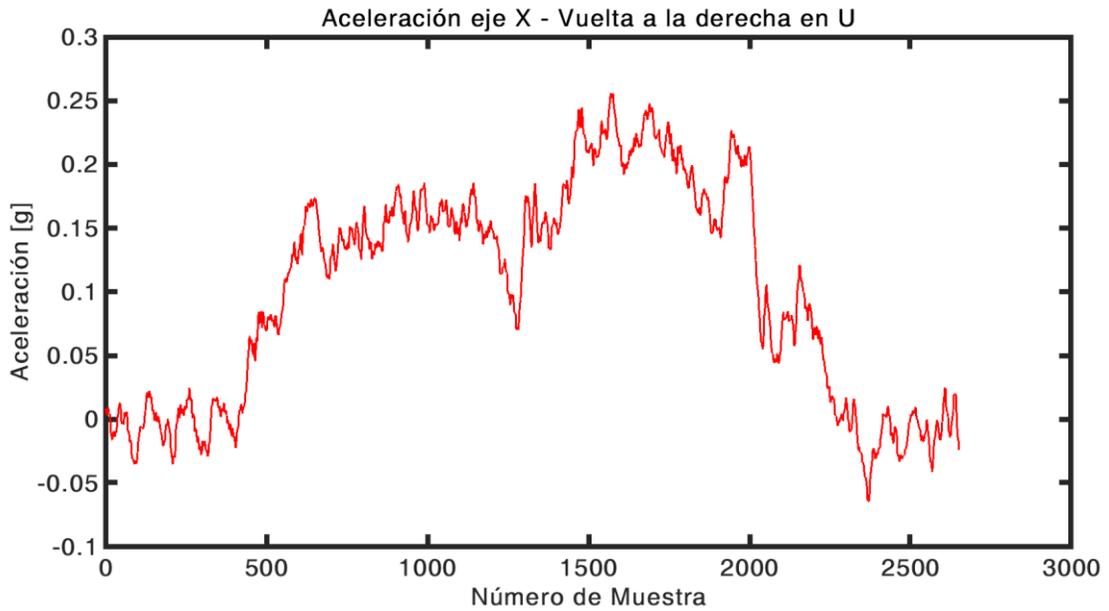


Figura B.46: Gráfica de la aceleración en el eje x (A_x) para el evento Vuelta a la derecha en U.

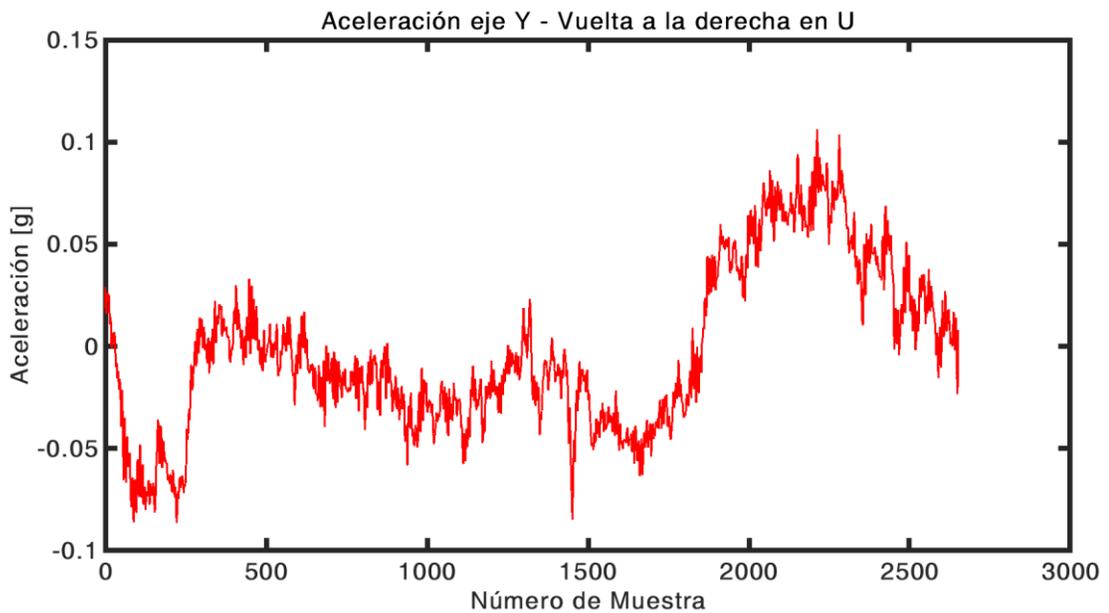


Figura B.47: Gráfica de la aceleración en el eje y (A_y) para el evento Vuelta a la derecha en U.

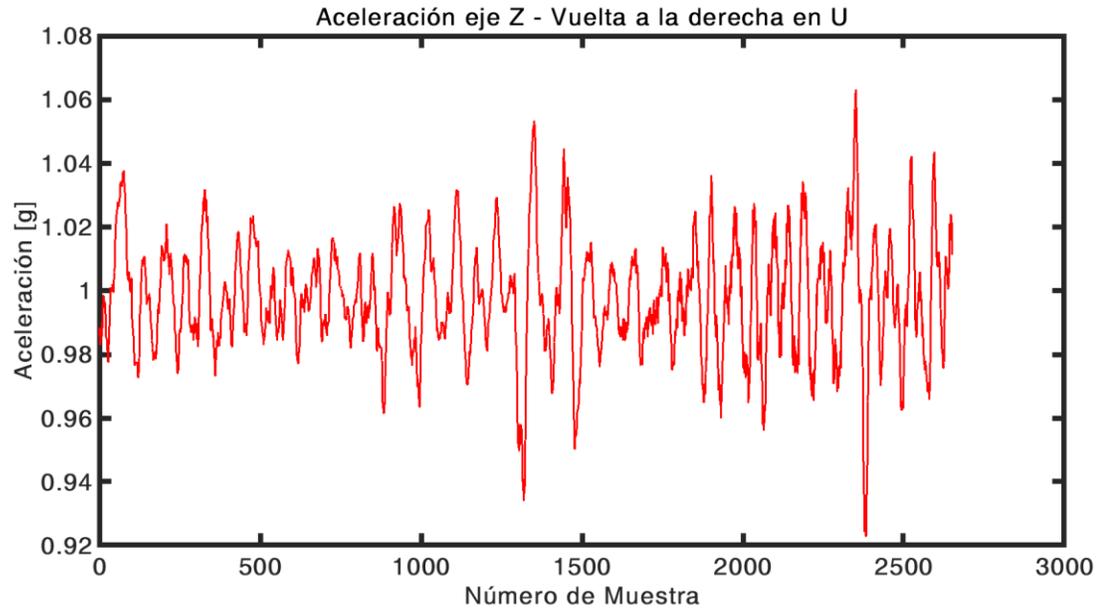


Figura B.48: Gráfica de la aceleración en el eje z (A_z) para el evento Vuelta a la derecha en U.

Velocidad angular

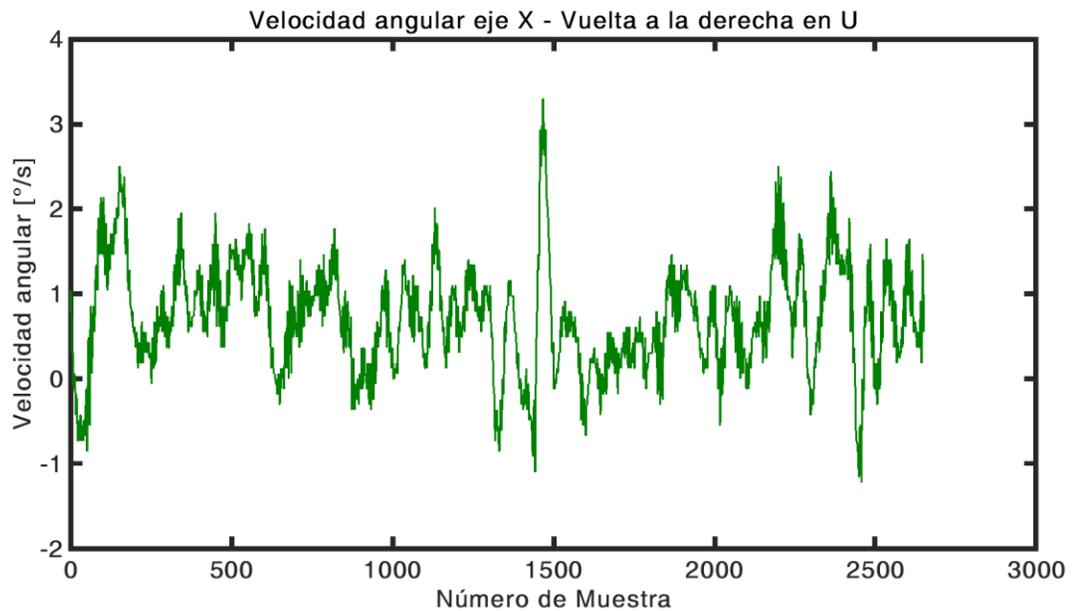


Figura B.49: Gráfica de la velocidad angular en el eje x (G_x) para el evento Vuelta a la derecha en U.

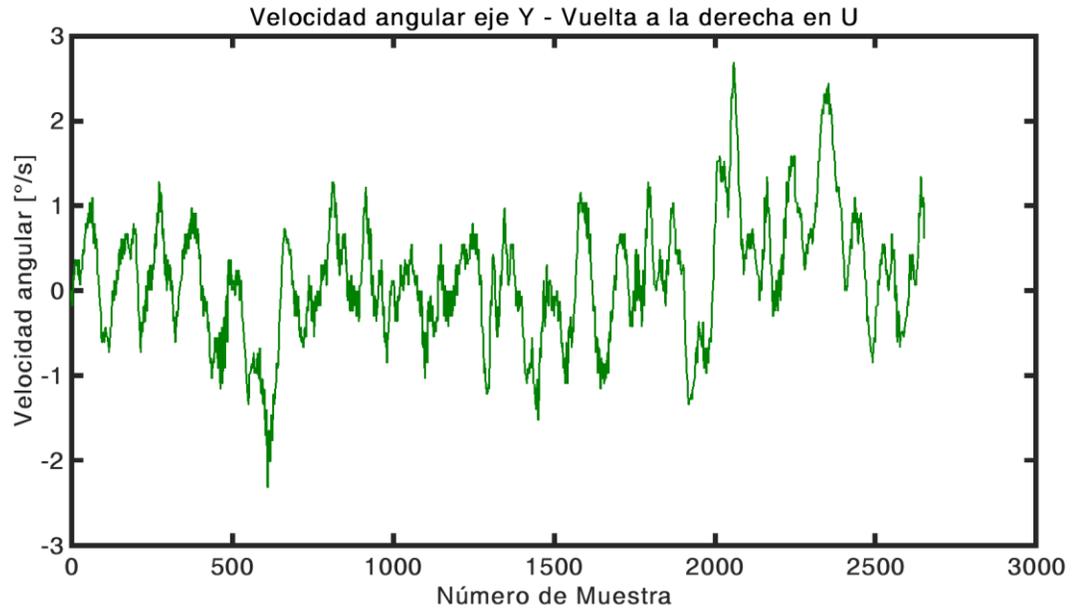


Figura B.50: Gráfica de la velocidad angular en el eje y (G_y) para el evento Vuelta a la derecha en U.

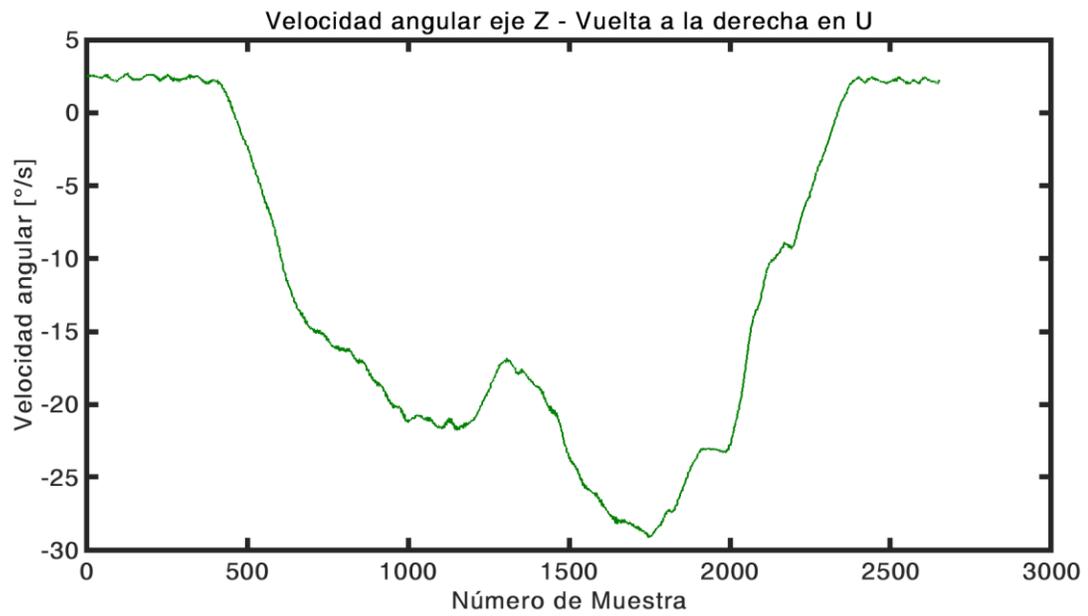


Figura B.51: Gráfica de la velocidad angular en el eje z (G_z) para el evento Vuelta a la derecha en U.

Ángulo de giro

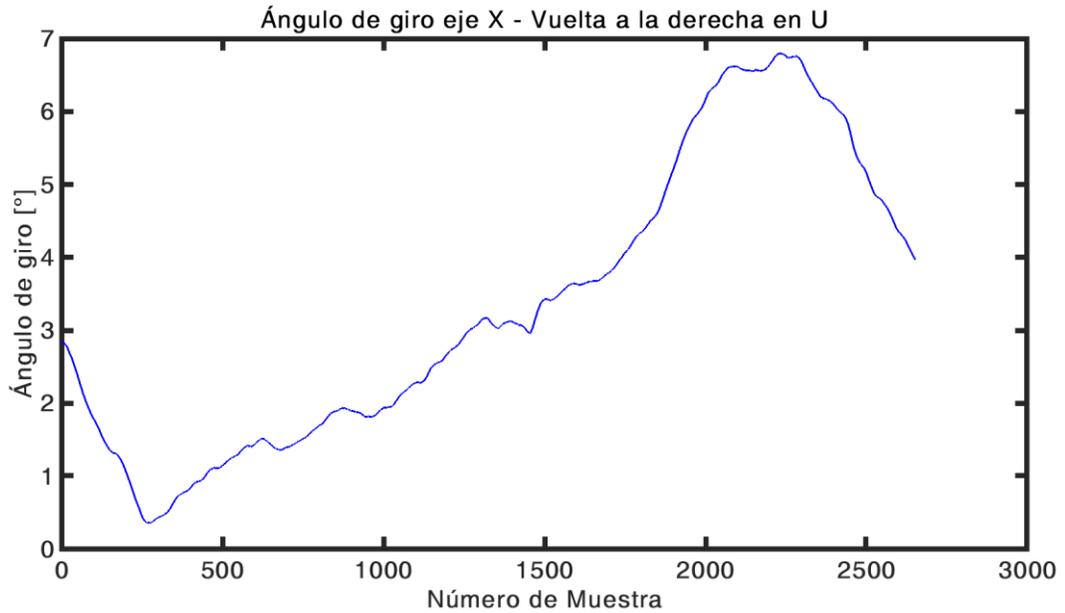


Figura B.52: Gráfica del ángulo de giro en el eje x (E_x) para el evento Vuelta a la derecha en U, relativo a la dirección donde se detectó el inicio del evento.

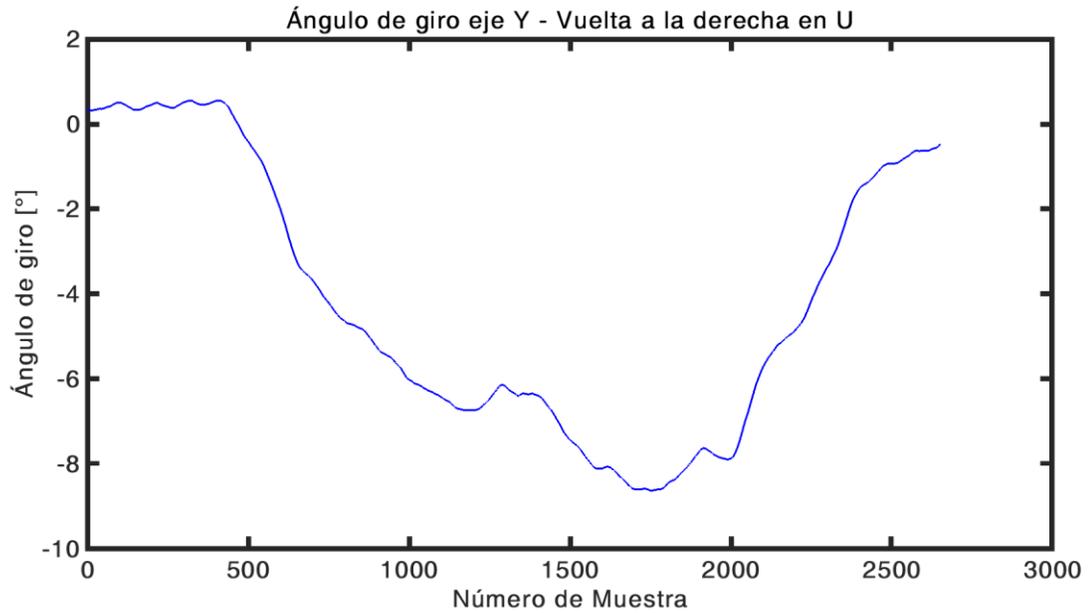


Figura B.53: Gráfica del ángulo de giro en el eje y (E_y) para el evento Vuelta a la derecha en U, relativo a la dirección donde se detectó el inicio del evento.

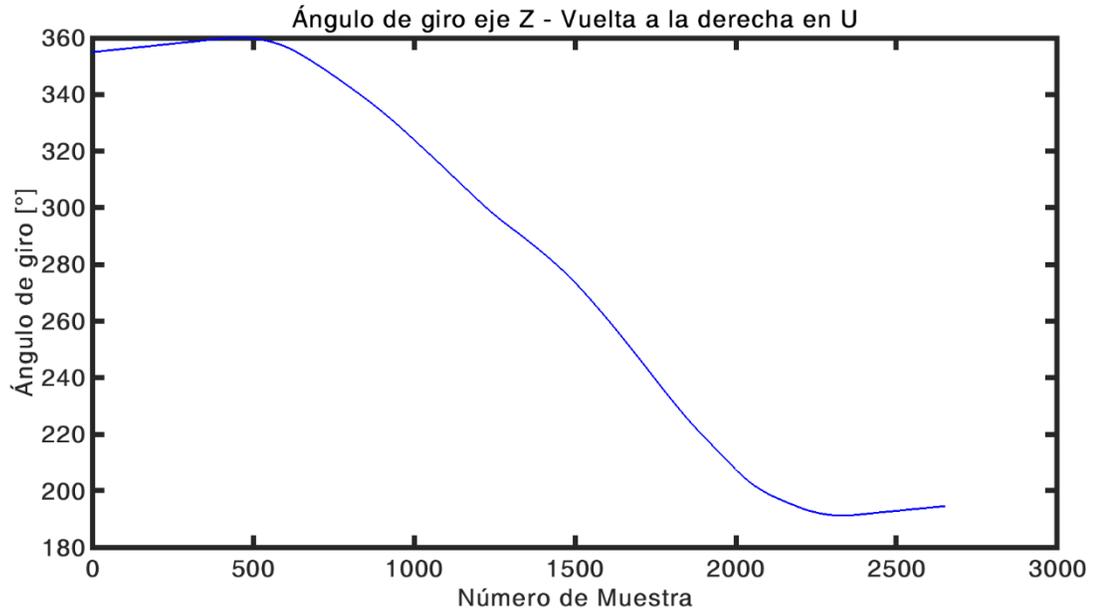


Figura B.54: Gráfica del ángulo de giro en el eje z (E_z) para el evento Vuelta a la derecha en U, relativo a la dirección donde se detectó el inicio del evento.

Categoría: Camino

Evento: Tope

Aceleración

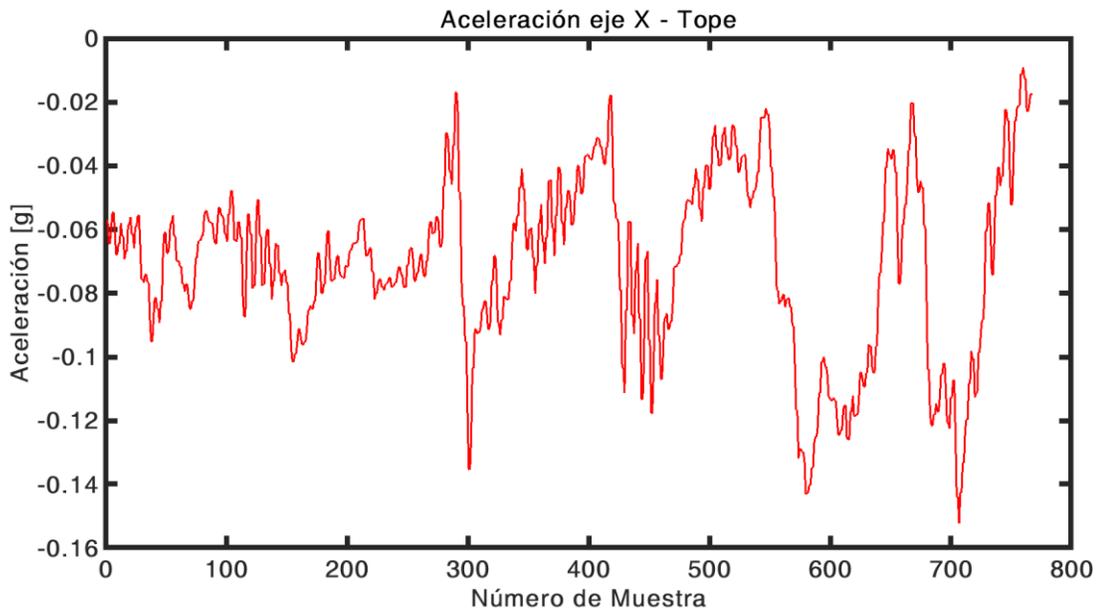


Figura B.55: Gráfica de la aceleración en el eje x (A_x) para el evento Tope.

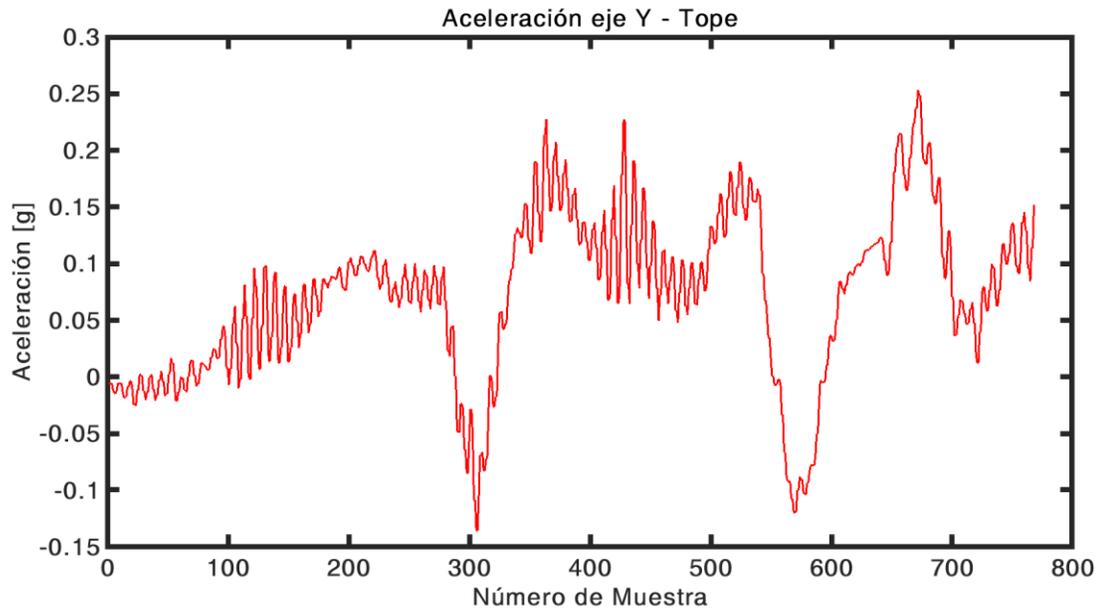


Figura B.56: Gráfica de la aceleración en el eje y (A_y) para el evento Tope.

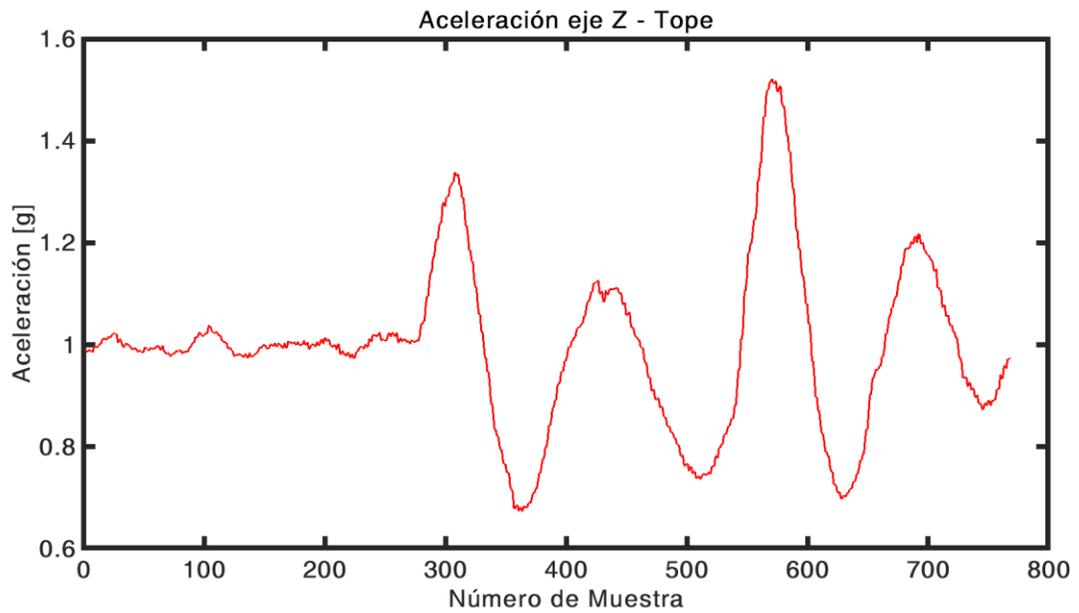
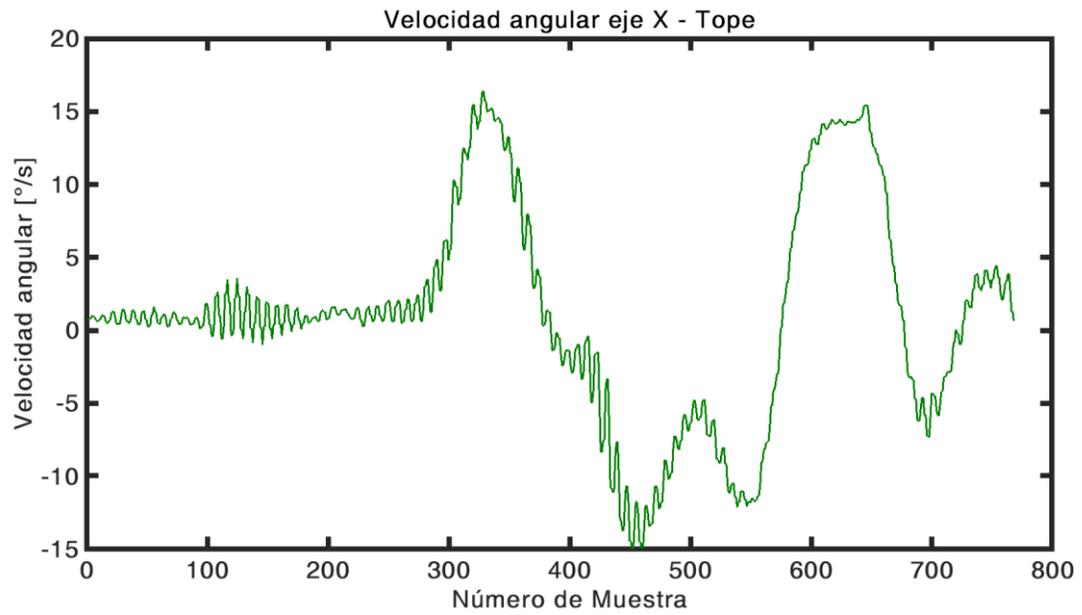
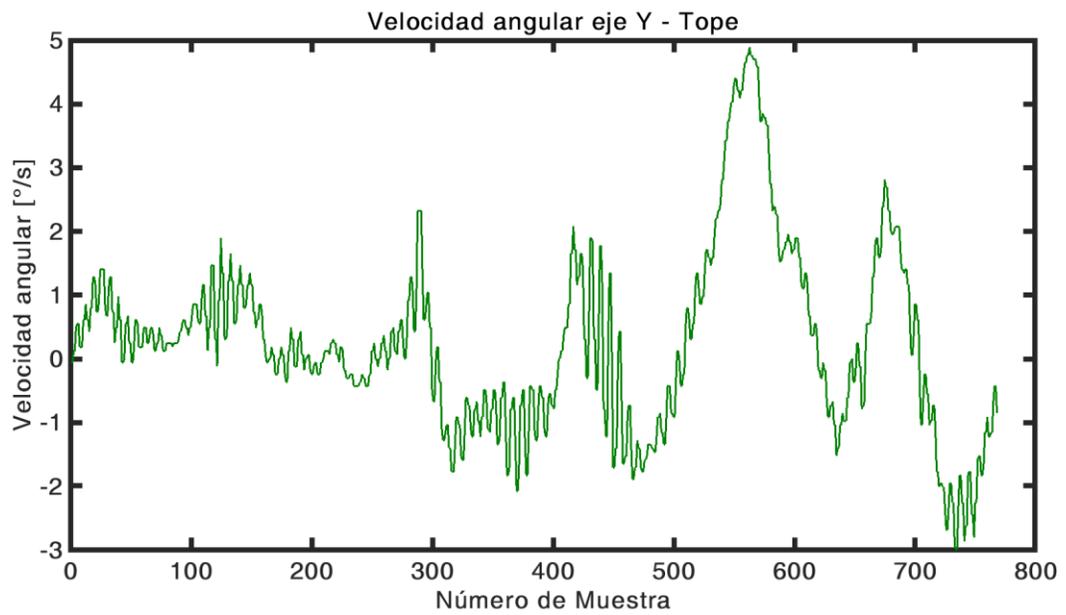


Figura B.57: Gráfica de la aceleración en el eje z (A_z) para el evento Tope.

Velocidad angularFigura B.58: Gráfica de la velocidad angular en el eje x (G_x) para el evento Tope.Figura B.59: Gráfica de la velocidad angular en el eje y (G_y) para el evento Tope.

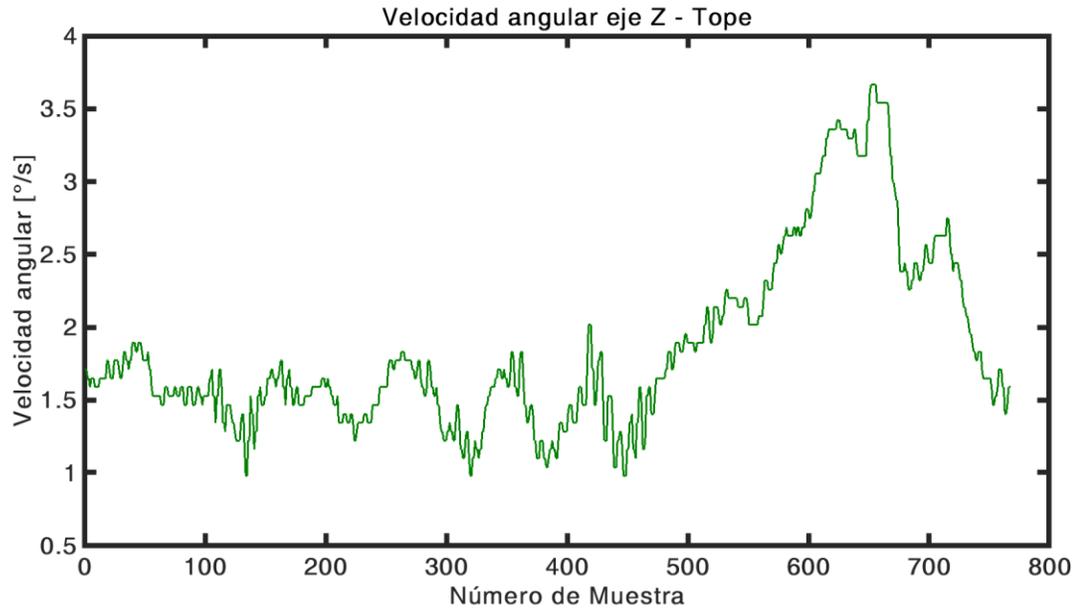


Figura B.60: Gráfica de la velocidad angular en el eje z (G_z) para el evento Tope.

Ángulo de giro

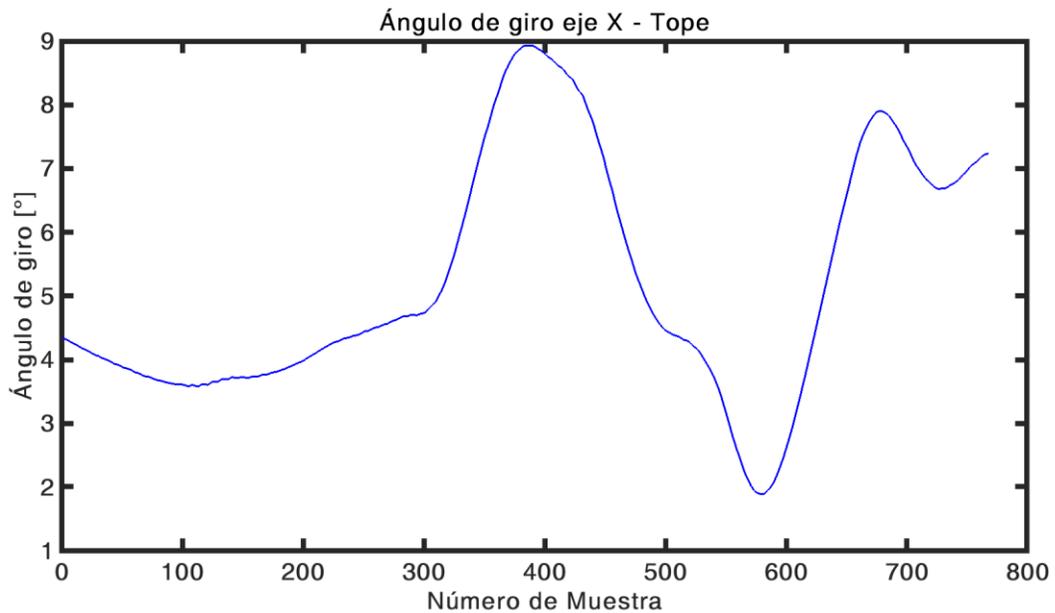


Figura B.61: Gráfica del ángulo de giro en el eje x (E_x) para el evento Tope, relativo a la dirección donde se detectó el inicio del evento.

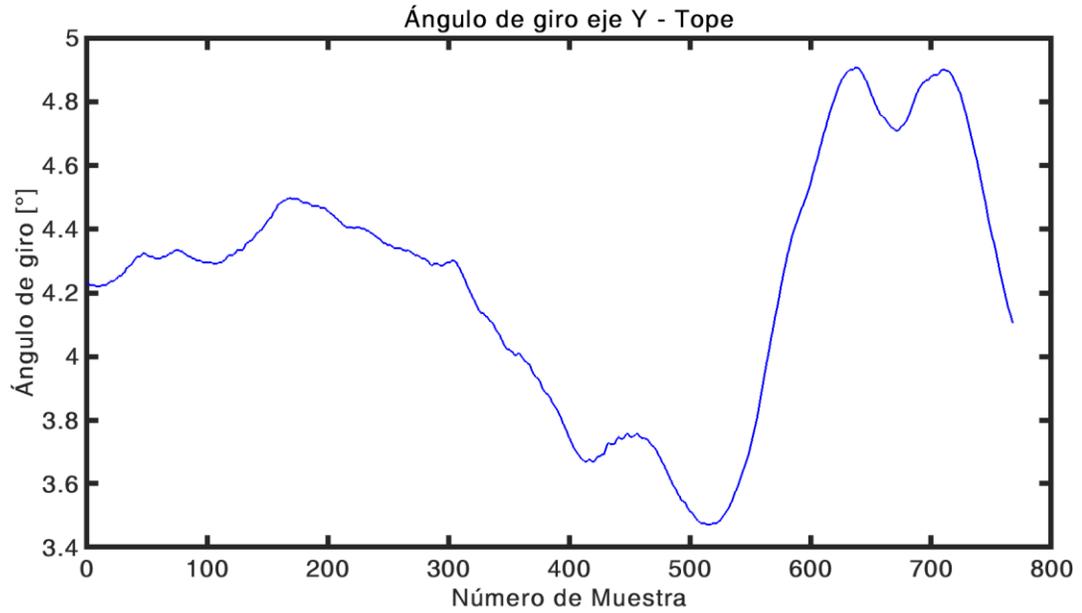


Figura B.62: Gráfica del ángulo de giro en el eje y (E_y) para el evento Tope, relativo a la dirección donde se detectó el inicio del evento.

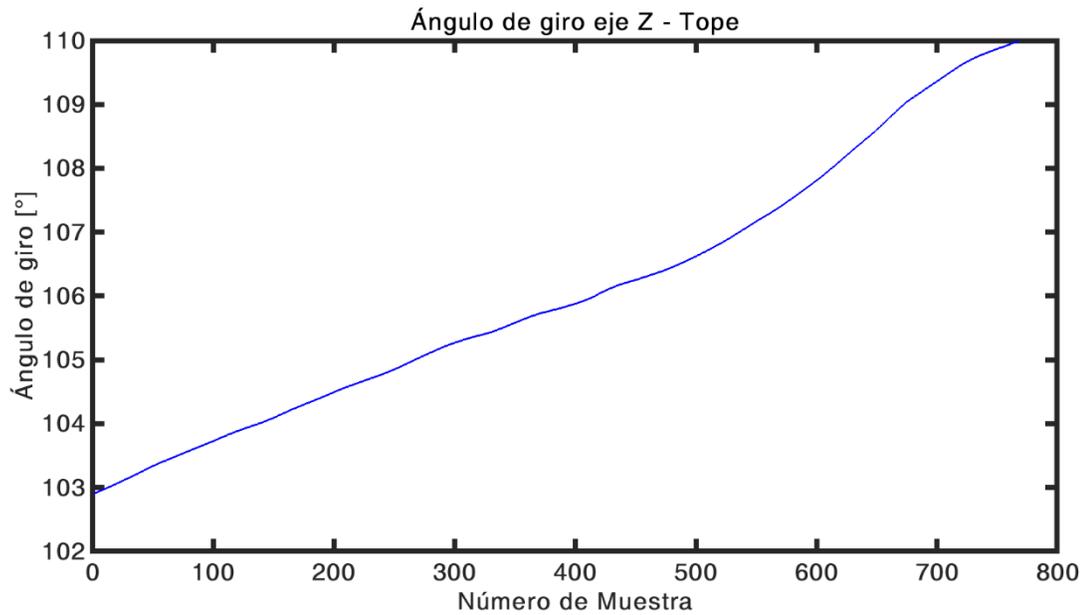


Figura B.63: Gráfica del ángulo de giro en el eje z (E_z) para el evento Tope, relativo a la dirección donde se detectó el inicio del evento.

Categoría: Camino

Evento: Bache

Aceleración

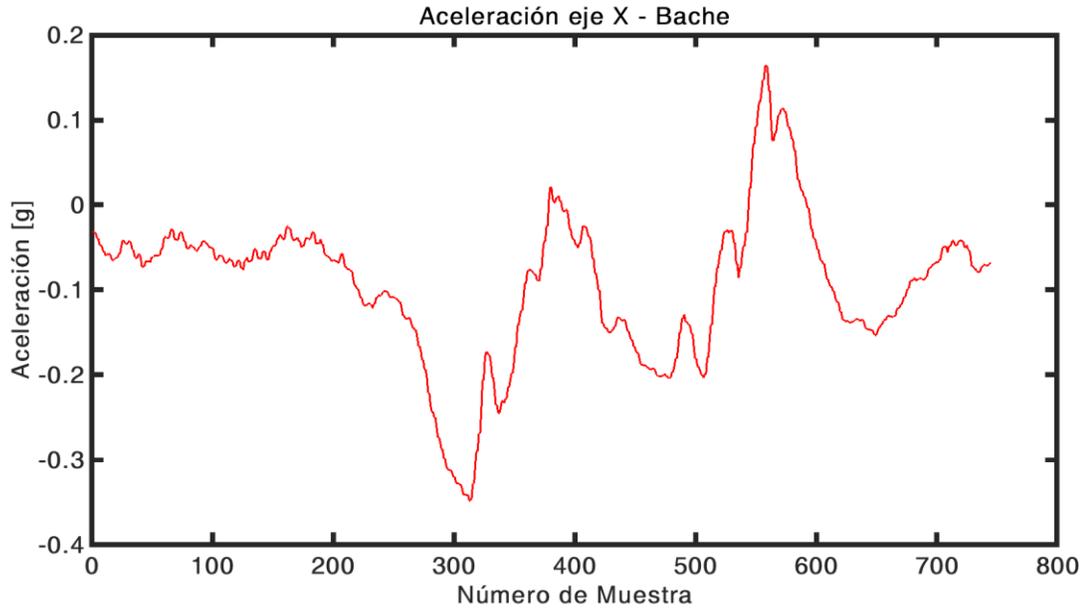


Figura B.64: Gráfica de la aceleración en el eje x (A_x) para el evento Bache.

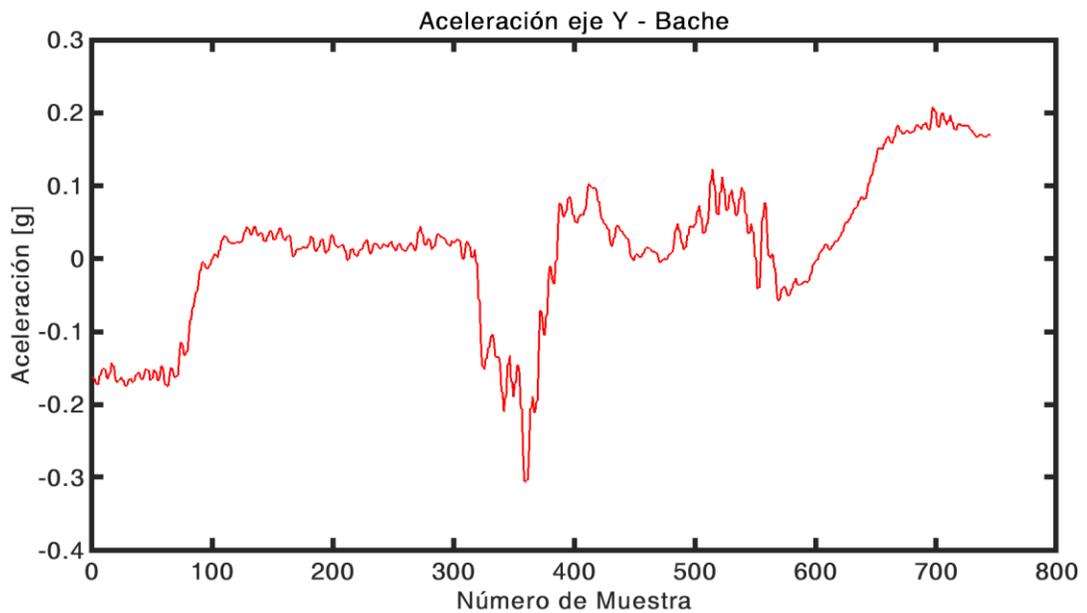


Figura B.65: Gráfica de la aceleración en el eje y (A_y) para el evento Bache.

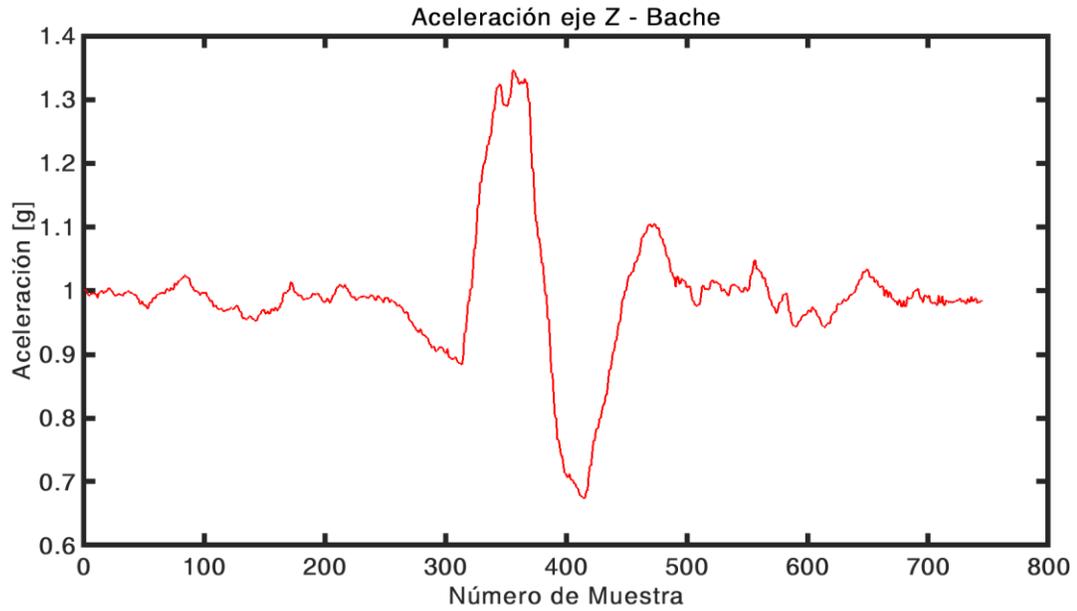


Figura B.66: Gráfica de la aceleración en el eje z (A_z) para el evento Bache.

Velocidad angular

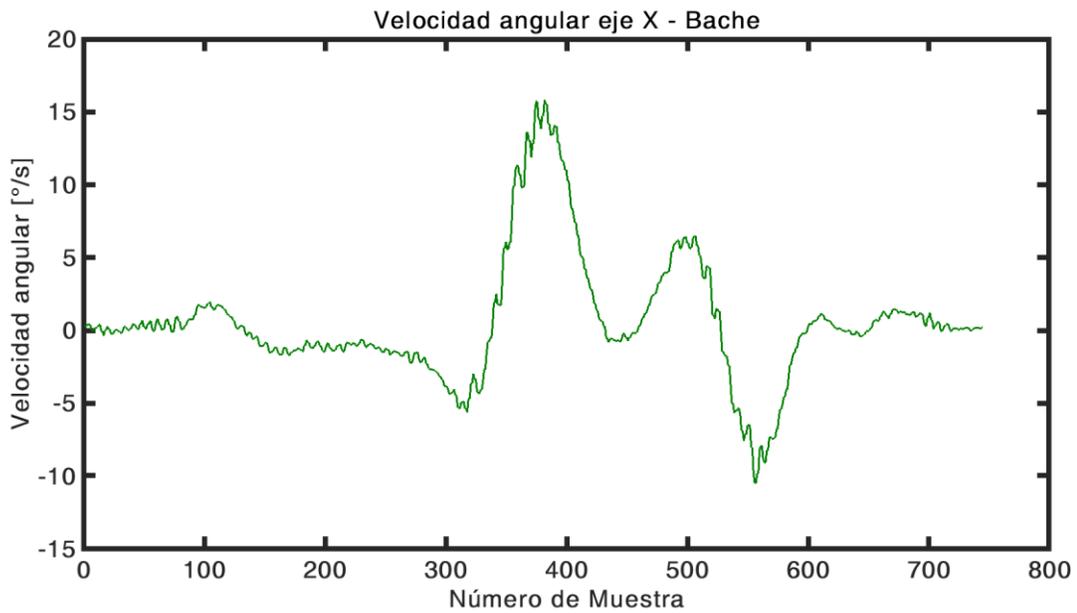


Figura B.67: Gráfica de la velocidad angular en el eje x (G_x) para el evento Bache.

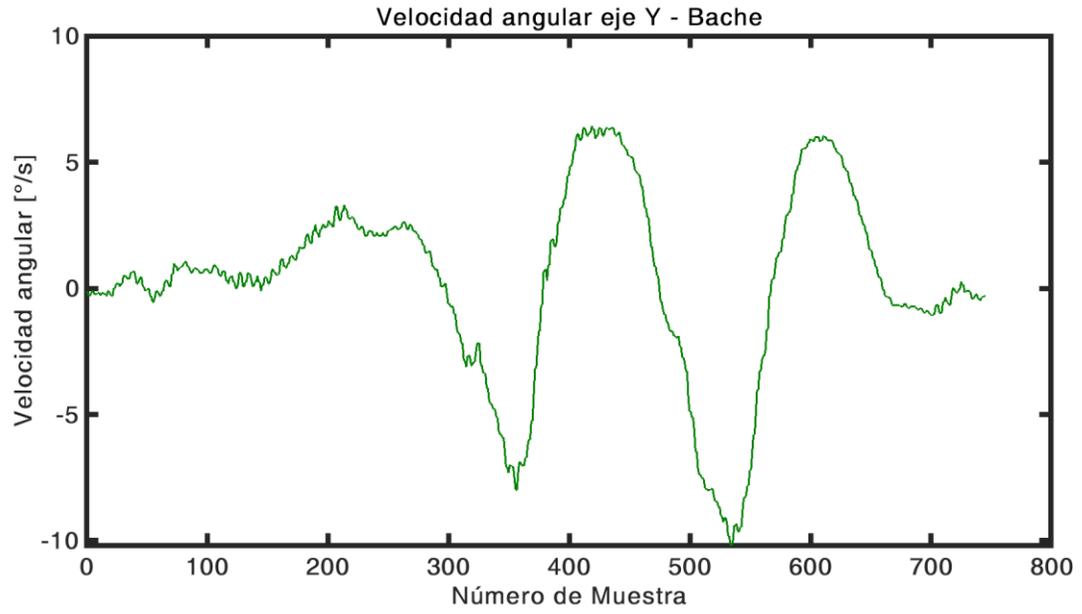


Figura B.68: Gráfica de la velocidad angular en el eje y (G_y) para el evento Bache.

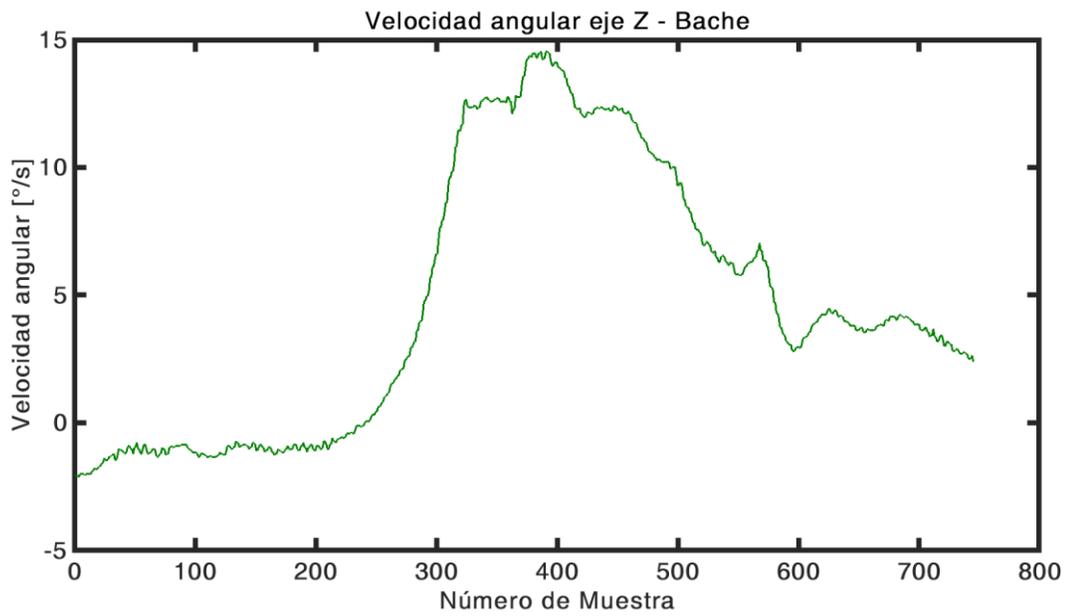


Figura B.69: Gráfica de la velocidad angular en el eje z (G_z) para el evento Bache.

Ángulo de giro

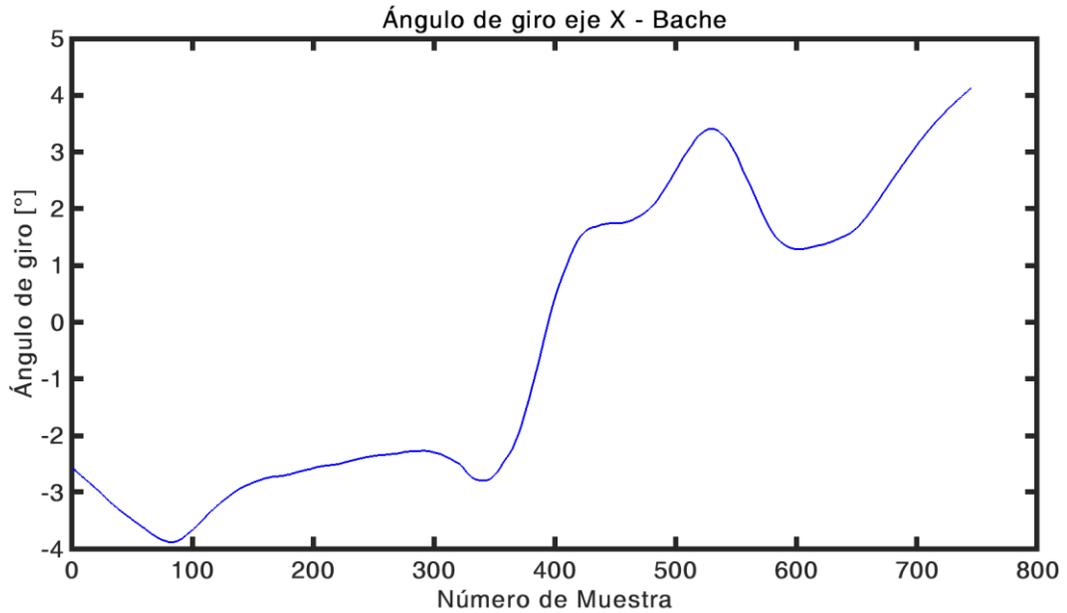


Figura B.70: Gráfica del ángulo de giro en el eje x (E_x) para el evento Bache, relativo a la dirección donde se detectó el inicio del evento.

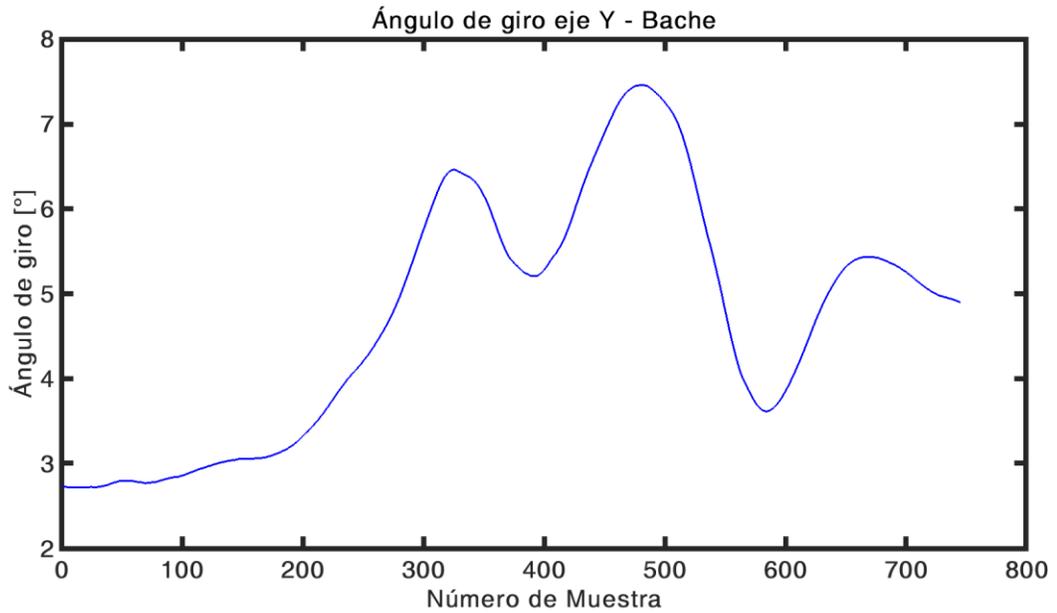


Figura B.71: Gráfica del ángulo de giro en el eje y (E_y) para el evento Bache, relativo a la dirección donde se detectó el inicio del evento.

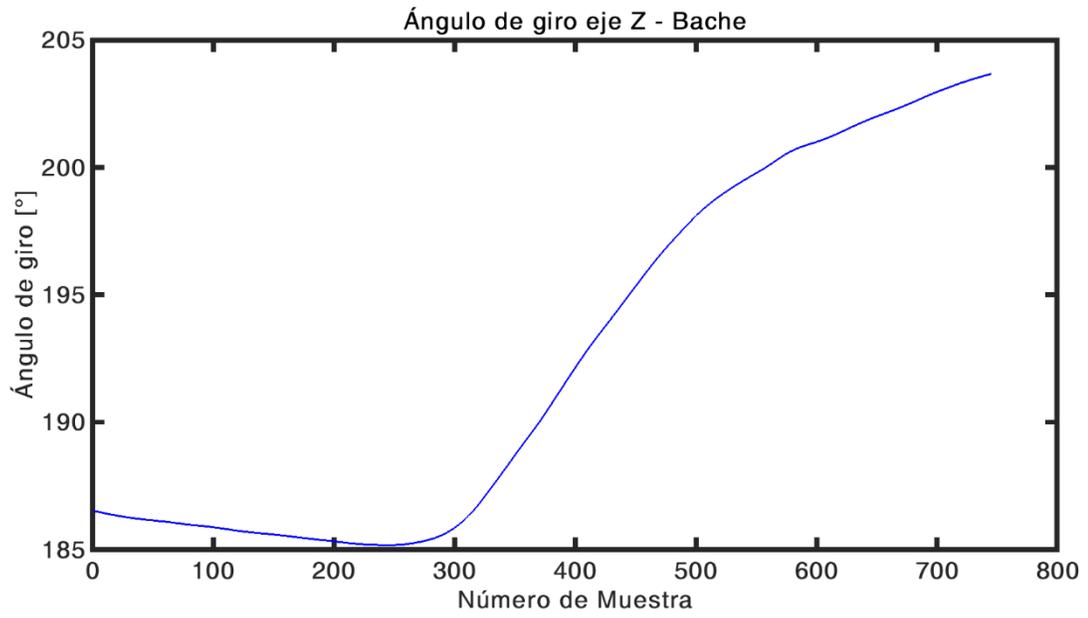


Figura B.72: Gráfica del ángulo de giro en el eje z (E_z) para el evento Bache, relativo a la dirección donde se detectó el inicio del evento.

REFERENCIAS

1. Número de unidades vehiculares registradas por los gobiernos estatales y municipales. Disponible en línea: <http://www.beta.inegi.org.mx/temas/vehiculos/> (consultado el 9 de Julio de 2018).
2. Número de accidentes de tránsito terrestre registrados por los gobiernos estatales y municipales. Disponible en línea: <http://www.beta.inegi.org.mx/temas/accidentes/> (consultado el 9 de Julio de 2018).
3. Mitrovic, D. Reliable method for driving events recognition. *IEEE Trans. Intell. Transp. Syst.* 2005, 6, 198–205.
4. Fazeen, M.; Gozick, B.; Dantu, R.; Bhukhiya, M.; Gonzalez, M.C. Safe Driving Using Mobile Phones. *IEEE Trans. Intell. Transp. Syst.* 2012, 13, 1462–1468.
5. Bergasa, L.M.; Almeria, D.; Almazan, J.; Yebes, J.J.; Arroyo, R. DriveSafe: An App for Alerting Inattentive Drivers and Scoring Driving Behaviors. In Proceedings of the 2014 IEEE Intelligent Vehicles Symposium Proceedings, Dearborn, MI, USA, 8–11 junio 2014; pp. 240–245.
6. Vaitkus, V.; Lengvenis, P.; Zylius, G. Driving Style Classification using Long-Term Accelerometer Information. In Proceedings of the 2014 19th International Conference on Methods and Models in Automation and Robotics (MMAR), Miedzyzdroje, Polonia, 2–5 septiembre 2014; pp. 641–644.
7. Johnson, D.A.; Trivedi, M.M. Driving Style Recognition Using a Smartphone as a Sensor Platform. In Proceedings of the 2011 14th International IEEE Conference on Intelligent Transportation Systems, Washington, DC, USA, 5–7 octubre 2011; pp. 1609–1615.
8. Maag, C.; Muhlbacher, D.; Mark, C.; Kruger, H.P. Studying Effects of Advanced Driver Assistance Systems (ADAS) on Individual and Group Level Using Multi-Driver Simulation. *IEEE Intell. Transp. Syst. Mag.* 2012, 4, 45–54.
9. Wiethoff, M.; Oei, H.L.; Penttinen, M.; Anttila, V.; Marchaud, V.A.W.J. Advanced Driver Assistance Systems: An Overview and Actor Position. In Proceedings of the 2002 15th IFAC World Conference, Barcelona, España, 21–26 julio 2002; pp. 1–6.
10. Takeda, K.; Hansen, J.H.L.; Boyraz, P.; Malta, L.; Miyajima, C.; Abut, H. International Large-Scale Vehicle Corpora for Research on Driver Behavior on the Road. *IEEE Trans. Intell. Transp. Syst.* 2011, 12, 1609–1623.

11. Dong, Y.C.; Hu, Z.C.; Uchimura, K.; Murayama, N. Driver Inattention Monitoring System for Intelligent Vehicles: A Review. *IEEE Trans. Intell. Transp. Syst.* 2011, 12, 596–614.
12. Ly, M.V.; Martin, S.; Trivedi, M.M. Driver Classification and Driving Style Recognition using Inertial Sensors. In Proceedings of the 2013 IEEE Intelligent Vehicles Symposium (IV), Gold Coast City, Australia, 23–26 junio 2013; pp. 1040–1045.
13. Sathyanarayana, A.; Sadjadi, S.O.; Hansen, J.H.L. Leveraging Sensor Information from Portable Devices towards Automatic Driving Maneuver Recognition. In Proceedings of the 15th International IEEE Conference on Intelligent Transportation Systems (ITSC), Anchorage, AK, USA, 16–19 septiembre 2012; pp. 660–665.
14. Dai, J.; Teng, J.; Bai, X.; Shen, Z.; Xuan, D. Mobile phone based drunk driving detection. In Proceedings of the 2010 4th International Conference on Pervasive Computing Technologies for Healthcare, Munchen, Alemania, 22–25 marzo 2010; pp. 1–8.
15. CAN technical documents. Disponible en línea: <http://www.ti.com/interface/can-lin/technical-documents.html> (consultado el 9 de julio de 2018).
16. On Board Diagnostics: Risks and Vulnerabilities of the Connected Vehicle. Disponible en línea: <https://resources.sei.cmu.edu/library/> (consultado el 9 de julio de 2018).
17. Koscher, K.; Czeskis, A.; Roesner, F.; Patel, S.; Kohno, T.; Checkoway, S.; McCoy, D.; Kantor, B.; Anderson, D.; Shacham, H.; et al. Experimental Security Analysis of a Modern Automobile. In Proceedings of the 2010 IEEE Symposium on Security and Privacy, Oakland, CA, USA, 16–19 mayo 2010; pp. 447–462.
18. Song, C.W.; Nam, K.W.; Lee, C.W. Driving Pattern Recognition System Using Smartphone sensor stream. *J. Korea Soc. Ind. Inform. Syst.* 2012, 17, 35–42.
19. Higgs, B.; Abbas, M. Segmentation and Clustering of Car-Following Behavior: Recognition of Driving Patterns. *IEEE Trans. Intell. Transp. Syst.* 2015, 16, 81–90.
20. Wang, R.; Lukic, S.M. Review of driving conditions prediction and driving style recognition based control algorithms for hybrid electric vehicles. In Proceedings of the 2011 IEEE Vehicle Power and Propulsion Conference, Chicago, IL, USA, 6–9 septiembre 2011; pp. 1–7.
21. Doerr, D.; Grabengieser, D.; Gauterin, F. Online Driving Style Recognition Using Fuzzy Logic. In Proceedings of the 2014 IEEE 17th International Conference on Intelligent Transportation Systems (ITSC), Qingdao, China, 8–11 octubre 2014; pp. 1021–1026.
22. Rygula, A. Driving Style Identification Method Based on Speed Graph Analysis. In Proceedings of the 2009 International Conference on Biometrics and Kansei Engineering (ICBAKE 2009), Cieszyn, Polonia, 25–28 junio 2009; pp. 76–79.

23. Minglin, W.; Sheng, Z.; Yuhan, D. A Novel Model-Based Driving Behavior Recognition System Using Motion Sensors. *MDPI Sensors* 2016, 16, 1746–1768.
24. CarMaker: Virtual testing of automobiles and light-duty vehicles. Disponible en línea: <https://ipg-automotive.com/products-services/simulation-software/carmaker/> (consultado el 18 de agosto de 2018).
25. Barke, A.; Niemeier, C. Method for operating a motor vehicle and associated motor vehicle, Patente U.S. 2018/0057015A1, septiembre 2017.
26. Oduor, E.N.; Omondi, S.; Tatsubori, M.; Walcott, A.; Wamburu J.M. System and method for context-based driver monitoring, Patente U.S. 2018/0060970A1, febrero 2017.
27. Naturalistic Driving: Observing everyday driving behaviour. Institute for road safety research, Leidschendam, Holanda, octubre 2012, 1–5.
28. The Scientist & Engineer's Guide to Digital Signal Processing. Disponible en línea: http://www.analog.com/en/education/education-library/scientist_engineers_guide.html (consultado el 5 de septiembre de 2018).
29. Keogh, E.J.; Pazzani M.J. Derivative Dynamic Time Warping. In Proceedings of the 2001 1st SIAM International Conference on Data Mining (SDM 2001), Chicago, IL, USA, 5–7 abril 2001.
30. Sakoe, H.; Chiba, S. Dynamic programming algorithm optimization for spoken word recognition. *IEEE Trans. Acous. Spee. Sign. Proce.* 1978, 26, 43–49.
31. Bhanu, B.; Zhou, X. Face recognition from face profile using dynamic time warping. In Proceedings of the 2004 17th International Conference on Pattern Recognition (ICPR 2004), Cambridge, Reino Unido, 23–26 agosto 2004; pp. 499–502.
32. Halachkin, A. Dynamic time warping for vehicle classification. In Proceedings of the 2015 21st Conference of Student, Electrical Engineering, Information and Communication Technologies (EEICT 2015), Brno, República Checa, 2015; pp. 156–158.
33. Munich, M.E.; Perona, P. Continuous dynamic time warping for translation-invariant curve alignment with applications to signature verification. In Proceedings of the 1999 7th International Conference on Computer Vision (ICCV 1999), Kofu, Grecia, 20–27 septiembre 1999; pp. 108–115.
34. Agrawal, R.; Ram, B. A Modified K-Nearest Neighbor Algorithm to Handle Uncertain Data. In Proceedings of the 2015 5th International Conference on IT Convergence and Security (ICITCS 2015), Kuala Lumpur, Malasia, 24–27 agosto 2015; pp. 1–4.

35. Jose, J.P.; Poornima, P.; Kumar, K.M. A novel method for color face recognition using KNN classifier. In Proceedings of the 2012 International Conference on Computing, Communication and Applications (ICCCA 2012), Dindigul, Tamilnadu, India, 22–24 febrero 2012; pp. 1–3.
36. Tahmasebi, A.; Pourghassem, H. Signature Identification Using Dynamic and HMM Features and KNN Classifier. In Proceedings of the 2013 International Conference on Communication Systems and Network Technologies (ICCSNT 2013), Gwalior, India, 6–8 abril 2013; pp. 201–205.
37. Dudani, S.A. The Distance-Weighted k-Nearest-Neighbor Rule. *IEEE Trans. Sys. and Cyber.* 1976, 6, 325–327.
38. Janota, A.; Šimák, V.; Nemeč, D.; Hrbček, J. Improving the Precision and Speed of Euler Angles Computation from Low-Cost Rotation Sensor Data. *MDPI Sensors* 2015, 15, 7016–7039.
39. McCune, B.P.; Grace, J. “Distance Measures” en *Analysis of Ecological Communities*, MJM Software, Gleneden Beach, Oregon, 2002, pp. 45–57.
40. Hansun, S. A new approach of moving average method in time series analysis. In Proceedings of the 2013 Conference on New Media Studies (CoNMedia 2013), Tangerang, China, 27–28 noviembre 2013; pp. 1–4.
41. Chérigo, C.; Rodríguez, H. Evaluation of data fusion algorithms for attitude estimation of unmanned aerial vehicles. *I+D Tecnológico* 2017, 13, 90–99.
42. Itakura, F. Minimum prediction residual principle applied to speech recognition. *IEEE Trans. Acoust. Speech Signal Processing*. vol. ASSP-23, febrero 1975, pp. 67–72.
43. Serial Bluetooth Terminal. Disponible en línea: https://play.google.com/store/apps/details?id=de.kai_morich.serial_bluetooth_terminal (consultado el 20 de enero de 2019).



Casa abierta al tiempo

UNIVERSIDAD AUTÓNOMA METROPOLITANA

ACTA DE EXAMEN DE GRADO

No. 00084

Matrícula: 2163802731

Detección de eventos de conducción en vehículos terrestres por medio de sensores inerciales.

En la Ciudad de México, se presentaron a las 10:00 horas del día 16 del mes de diciembre del año 2019 en la Unidad Iztapalapa de la Universidad Autónoma Metropolitana, los suscritos miembros del jurado:

DR. ROGELIO REYES REYES
DR. LUIS MARTIN ROJAS CARDENAS
DR. PEDRO LARA VELAZQUEZ



OSCAR HUERTA SOLIS
ALUMNO

Bajo la Presidencia del primero y Con carácter de Secretario el último, se reunieron para proceder al Examen de Grado cuya denominación aparece al margen, para la obtención del grado de:

MAESTRO EN CIENCIAS (CIENCIAS Y TECNOLOGIAS DE LA INFORMACION)

DE: OSCAR HUERTA SOLIS

y de acuerdo con el artículo 78 fracción III del Reglamento de Estudios Superiores de la Universidad Autónoma Metropolitana, los miembros del jurado resolvieron:

Aprobar

REVISÓ

MTRA. ROSALBA SERRANO DE LA PAZ
DIRECTORA DE SISTEMAS ESCOLARES

Acto continuo, el presidente del jurado comunicó al interesado el resultado de la evaluación y, en caso aprobatorio, le fue tomada la protesta.

DIRECTOR DE LA DIVISIÓN DE CBI

DR. JESUS ALBERTO OCHOA TAPIA

PRESIDENTE

DR. ROGELIO REYES REYES

VOCAL

DR. LUIS MARTIN ROJAS CARDENAS

SECRETARIO

DR. PEDRO LARA VELAZQUEZ