



ESPE

UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA

**CARRERA DE INGENIERÍA EN ELECTRÓNICA,
AUTOMATIZACIÓN Y CONTROL**

**TRABAJO DE TITULACIÓN, PREVIO A LA OBTENCIÓN DEL
TÍTULO DE INGENIERA EN ELECTRÓNICA,
AUTOMATIZACIÓN Y CONTROL**

**TEMA: IMPLEMENTACIÓN DEL ALGORITMO DE
CLASIFICACIÓN BAYESIAN NAIVE Y EL FILTRO DE KALMAN
PARA LA DETECCIÓN Y SEGUIMIENTO DE PEATONES PARA
APLICACIONES EN VEHÍCULOS INTELIGENTES**

**AUTORES: CADENA PAILLACHO, EDISON BLADIMIR
CHÁVEZ CHAMORRO, WILLIAM PAÚL**

DIRECTOR: Dr. FLORES CALERO, MARCO JAVIER.

SANGOLQUÍ

2018



ESPE

UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA
CARRERA DE INGENIERÍA EN ELECTRÓNICA, AUTOMATIZACIÓN Y
CONTROL

CERTIFICACIÓN

Certifico que el trabajo de titulación, *“IMPLEMENTACIÓN DEL ALGORITMO DE CLASIFICACIÓN BAYESIAN NAIVE Y EL FILTRO DE KALMAN PARA LA DETECCIÓN Y SEGUIMIENTO DE PEATONES PARA APLICACIONES EN VEHÍCULOS INTELIGENTES”* realizado por los señores *EDISON BLADIMIR CADENA PAILLACHO* y *WILLIAM PAÚL CHÁVEZ CHAMORRO*, ha sido revisado en su totalidad y analizado por el software anti-plagio, el mismo cumple con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Universidad de Fuerzas Armadas ESPE, por lo tanto me permito acreditarlo y autorizar a la señorita *EDISON BLADIMIR CADENA PAILLACHO WILLIAM PAÚL CHÁVEZ CHAMORRO* para que lo sustente públicamente.

Sangolquí, 12 de Enero del 2018.

Dr. Marco Javier Florez Calero



DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA
CARRERA DE INGENIERÍA EN ELECTRÓNICA, AUTOMATIZACIÓN Y
CONTROL

AUTORÍA DE RESPONSABILIDAD

Nosotros, *EDISON BLADIMIR CADENA PAILLACHO*, con cédula de identidad N° 1725298085 y *WILLIAM PAÚL CHÁVEZ CHAMORRO*, con cédula de identidad N° 0401634167 declaramos que este trabajo de titulación “*IMPLEMENTACIÓN DEL ALGORITMO DE CLASIFICACIÓN BAYESIAN NAIVE Y EL FILTRO DE KALMAN PARA LA DETECCIÓN Y SEGUIMIENTO DE PEATONES PARA APLICACIONES EN VEHÍCULOS INTELIGENTES*” ha sido desarrollado considerando los métodos de investigación existentes, así como también se ha respetado los derechos intelectuales de terceros considerándose en las citas bibliográficas.

Consecuentemente declaramos que este trabajo es de nuestra autoría, en virtud de ello declaramos responsables del contenido, veracidad y alcance de la investigación mencionada.

Sangolquí, 12 de Enero del 2018.

Edison Bladimir Cadena Paillacho
CC: 1725298085

William Paúl Chávez Chamorro
CC:0401634167



ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA
CARRERA DE INGENIERÍA EN ELECTRÓNICA, AUTOMATIZACIÓN Y
CONTROL

AUTORIZACIÓN

Nosotros, *EDISON BLADIMIR CADENA PAILLACHO* y *WILLIAM PAÚL CHÁVEZ CHAMORRO*, autorizamos a la Universidad de las Fuerzas Armadas ESPE publicar en la biblioteca Virtual de la institución el presente trabajo de titulación “*IMPLEMENTACIÓN DEL ALGORITMO DE CLASIFICACIÓN BAYESIAN NAIVE Y EL FILTRO DE KALMAN PARA LA DETECCIÓN Y SEGUIMIENTO DE PEATONES PARA APLICACIONES EN VEHÍCULOS INTELIGENTES*” cuyo contenido, ideas y criterios son de nuestra autoría y responsabilidad.

Sangolquí, 12 de Enero del 2018.

Edison Bladimir Cadena Paillacho
CC: 1725298085

William Paúl Chávez Chamorro
CC:0401634167

DEDICATORIA

A mi familia y amigos, me han formado como persona y siempre han creído en mí. Les dedico este trabajo de investigación, pues gracias a ustedes he conseguido todas mis metas.

A mi madre Blanca por todo el cariño y comprensión siempre, A mi padre Edwin por enseñarme a que todo es posible si uno se lo propone y que las cosas si las hace uno mismo es mejor.

A mis hermanos Javier y Catherine por apoyarme en mis travesuras y ser un apoyo cuando lo he necesitado, A mi sobrino Carlitos por llenar con alegría siempre a toda mi familia con sus juegos y ocurrencias

Edison Bladimir Cadena Paillacho

DEDICATORIA

A mis padres Galo Chávez y Mery Chamorro: Es tiempo de cosecha de lo que ustedes mis queridos padres con infinito amor depositaron en mí y dedicaron su vida sus sueños y esfuerzo, permítanme entonces ofrecerles el fruto de su sacrificio de sus consejos y perseverancia que se materializa hoy en mi culminación de los estudios previo a la obtención del título que junto a los valores humanos que ustedes inculcaron por siempre en mi serán la llave que permitirá abrir nuevas metas y horizontes.

William Paúl Chávez Chamorro

AGRADECIMIENTO

Doy nuevamente gracias a mis padres y hermanos por el apoyo emocional y económico incondicional brindado.

De manera especial al Doctor Marco Flores por haber compartido sus conocimientos, experiencias y tiempo durante el desarrollo de este trabajo y así poder concluir con éxito mi carrera.

Edison Bladimir Cadena Paillacho

AGRADECIMIENTO

En primer lugar permitirme dar gracias a Dios, por darme una familia que es la esencia misma de mi ser, sobre todo a mis padres que forjaron en mí los cimientos mismos del alma e inculcaron por siempre valores como la responsabilidad honestidad y respeto, la verdad y el trabajo con una dosis de amor y sapiencia que formo en mí el templo necesario para llegar a cumplir mis metas propuestas.

De igual forma una infinita gratitud a mis apreciados maestros que transmitieron en mí sus valiosos conocimientos y ejemplos de vida, un agradecimiento al Dr. Marco Flores que supo guiarme y orientarme en nuestro proyecto que permitió culminar con éxito mi sueño que hoy se convierte en una prometedora realidad y son parte por siempre de mi proyecto de vida.

No me podría olvidar de aquellos con los que transite el mismo camino, compartimos las alegrías y las tristezas y momentos que llevaremos en nuestros recuerdos, si gratitud a mis amigos y compañeros de estudios por siempre.

William Paúl Chávez Chamorro

ÍNDICE DE CONTENIDOS

CERTIFICACIÓN.....	ii
AUTORÍA DE RESPONSABILIDAD.....	iii
AUTORIZACIÓN.....	iv
DEDICATORIA.....	v
DEDICATORIA.....	vi
AGRADECIMIENTO	vii
AGRADECIMIENTO	viii
ÍNDICE DE CONTENIDOS.....	ix
ÍNDICE DE TABLAS.....	xi
ÍNDICE DE FIGURAS.....	xii
RESUMEN.....	xvii
ABSTRACT.....	xviii
CAPÍTULO I.....	1
1. INTRODUCCIÓN	1
1.1. Antecedentes	1
1.2. Sistemas inteligentes de transporte	1
1.2.1. Clasificación de los sistemas inteligentes de transporte	3
1.3. Accidentes de tránsito	4
1.3.1. Accidentes de tránsito a nivel mundial	4
1.3.2. Accidentes de tránsito en Latino América	4
1.3.3. Accidentes de tránsito en el Ecuador	5
1.4. Justificación e Importancia.....	8
1.5. Alcance del proyecto	10
1.6. Objetivos	11
1.6.1. Objetivo general.....	11
1.6.2. Objetivos específicos	11
CAPÍTULO II	12
2. ESTADO DEL ARTE	12

2.1.	Introducción	12
2.2.	Clasificación de Peatones.....	12
2.3.	Seguimiento y estimación de la trayectoria de un peatón	18
CAPITULO III.....		19
3. CLASIFICACIÓN DE PERSONAS.....		19
3.1.	Introducción	19
3.2.	Generación de características usando el descriptor HOG	21
3.3.	Construcción del clasificador débil usando Naive- Bayes	22
3.4.	Construcción del clasificador fuerte usando Adaboosts y Naive-Bayes	27
3.5.	Resultados parciales	30
CAPÍTULO IV		36
4. SEGUIMIENTO Y ESTIMACIÓN DE LA TRAYECTORIA DE UN PEATÓN.....		36
4.1	Introducción	36
4.2	Filtro de Kalman aplicado al seguimiento de personas.....	37
4.3	Generación de la trayectoria de los peatones	45
CAPITULO V.....		47
5. PRUEBAS Y RESULTADOS.....		47
5.1.	Base de datos	47
5.2.	Curva ROC.....	48
5.3.	Curvas DET.....	55
5.4.	Resultados Experimentales del Clasificador	61
5.5.	Resultados Experimentales del Filtro de Kalman	64
CAPÍTULO VI.....		74
6. CONCLUSIONES Y TRABAJOS FUTUROS.....		74
6.1.	Conclusiones	74
6.2.	Trabajos futuros.....	75
REFERENCIAS BIBLIOGRÁFICAS.....		77
ANEXOS.....		87

ÍNDICE DE TABLAS

Tabla 1 <i>Evaluación de los clasificadores de personas según la tasa de fallas promedio logarítmica MR.</i>	13
Tabla 2 <i>Evaluación de la exactitud del clasificador Adaboost con descriptor HOG con la variación Ludwig.</i>	30
Tabla 3 <i>Evaluación de la exactitud del clasificador Adaboost con descriptor HOG con la variación Gao.</i>	31
Tabla 4 <i>Evaluación de la exactitud del clasificador Adaboost con descriptor HOG con la variación XU.</i>	31
Tabla 5 <i>Evaluación sensibilidad del clasificador Adaboost con descriptor HOG con la variación Ludwig.</i>	34
Tabla 6 <i>Evaluación sensibilidad del clasificador Adaboost Gao.</i>	34
Tabla 7 <i>Ecuaciones de la etapa de predicción del filtro de Kalman</i>	44
Tabla 8 <i>Ecuaciones de la etapa de corrección del filtro de Kalman</i>	44
Tabla 9 <i>Base de datos para el entrenamiento del clasificador Adaboost con Naive-Bayes.</i>	47
Tabla 10 <i>Resultados de evaluación de trayectoria</i>	71

ÍNDICE DE FIGURAS

Figura 1 Ejemplo de un sistema inteligente de transporte.	2
Figura 2 Evolución de accidentes de tránsito en Ecuador, 2006-2015.	6
Figura 3 Accidentes de tránsito en el ecuador según clase, 2015.	7
Figura 4 Evaluación de los heridos y muertos en accidentes de tránsito en Ecuador, 2006-2015.....	7
Figura 5 Fallecimiento por accidentes de tránsito provocados por el conductor Mayo 2016.....	9
Figura 6 Evaluación grafica de los clasificadores de personas según la tasa de fallas promedio logarítmica (MR).	17
Figura 7 Ejemplo de generación de ROIs para la clasificación de peatones.	19
Figura 8 Esquema para la detección de personas durante el día usando visión por computador.....	19
Figura 9 Principales problemas en la detección de peatones (a) y (b) motociclistas y ciclistas, (c) y (d) variación de condiciones meteorológicas y de iluminación, (e) y (f) personas ocluidas.	21
Figura 10 División de partes del cuerpo humano en varias regiones con distintas orientaciones.....	22
Figura 11 Distribución de datos del descriptor 40 por el método HOG en el caso de Gao (Xu & Gao, 2010).....	24
Figura 12 Esquema para la extracción de características HOG para el entrenamiento del algoritmo Naive- Bayes como clasificador débil.	25
Figura 13 Variación de la probabilidad $P(C_1)$ para el Método Ludwig.	26
Figura 14 Variación de la probabilidad $P(C_1)$ para el Método Gao.	27
Figura 15 Variación de la probabilidad $P(C_1)$ para el Método Xu.....	27
Figura 16 Diagrama de flujo del entrenamiento del clasificador fuerte Adaboost usando el clasificador Naive-Bayes como clasificador débil.....	29
Figura 17 Representación gráfica de la evaluación clasificador Adaboost con descriptor HOG con la variación Ludwig.	32

Figura 18 Representación gráfica de la evaluación del clasificador Adaboost con descriptor HOG con la variación Gao.....	32
Figura 19 Representación gráfica de la evaluación del clasificador Adaboost con descriptor HOG con la variación Xu.....	33
Figura 20 Representación gráfica de la evaluación de la sensibilidad del clasificador Adaboost con descriptor HOG con la variación Ludwig.....	34
Figura 21 Representación gráfica de la evaluación de la sensibilidad del clasificador Adaboost con descriptor HOG con la variación Gao.....	35
Figura 22 Principales problemas del seguimiento y estimación de la trayectoria de peatones; (a) y (b) falsas detecciones, (c) y (d) variación de iluminación.	37
Figura 23 Diagrama de flujo del seguimiento y estimación de la trayectoria de un peatón.....	38
Figura 24 (a) Eje de coordenadas en cada fotograma y (b) vector de estados en la ROI	40
Figura 25 Ciclo del Filtro de Kalman.....	43
Figura 26 Diagrama del funcionamiento del filtro de Kalman.....	45
Figura 27 Trayectoria de un peatón.....	46
Figura 28 Ejemplos de las bases de datos disponible: (a) P_T_IH, (b) CV-C, (c) INRIA, (d) Daimler, (e) MIT.....	48
Figura 29 Curva ROC para el clasificador Naive-Bayes + Adaboost con el descriptor HOG con la variación Ludwig con 3 clasificadores débiles.....	49
Figura 30 Curva ROC para el clasificador Naive-Bayes + con el descriptor HOG con la variación Ludwig con 6 clasificadores débiles.....	50
Figura 31 Curva ROC para el clasificador Naive-Bayes + Adaboost con el descriptor HOG con la variación Ludwig con 9 clasificadores débiles.....	50
Figura 32 Curva ROC para el clasificador Naive-Bayes + Adaboost con el descriptor HOG con la variación Ludwig con 12 clasificadores débiles.....	51
Figura 33 Curva ROC para el clasificador Naive-Bayes + Adaboost con el descriptor HOG con la variación Ludwig con 20 clasificadores débiles.....	51

Figura 34 Curva ROC para el clasificador Naive-Bayes + Adaboost con el descriptor HOG con la variación Gao con 3 clasificadores débiles.....	52
Figura 35 Curva ROC para el clasificador Naive-Bayes + Adaboost con el descriptor HOG con la variación Gao con 6 clasificadores débiles.....	53
Figura 36 Curva ROC para el clasificador Naive-Bayes + Adaboost con el descriptor HOG con la variación Gao con 9 clasificadores débiles.....	53
Figura 37 Curva ROC para el clasificador Naive-Bayes + Adaboost con el descriptor HOG con la variación Gao con 12 clasificadores débiles.....	54
Figura 38 Curva ROC para el clasificador Naive-Bayes + Adaboost con el descriptor HOG con la variación con 20 clasificadores débiles.....	54
Figura 39 Curva DET para el clasificador Nave-Bayes + Adaboost con el descriptor HOG con la variación Ludwig con 3 clasificadores débiles.	55
Figura 40 Curva DET para el clasificador Nave-Bayes + Adaboost con el descriptor HOG con la variación Ludwig con 6 clasificadores débiles.	56
Figura 41 Curva DET para el clasificador Nave-Bayes + con el descriptor HOG con la variación Ludwig con 9 clasificadores débiles.....	56
Figura 42 Curva DET para el clasificador Nave-Bayes + Adaboost con el descriptor HOG con la variación Ludwig con 12 clasificadores débiles.	57
Figura 43 Curva DET para el clasificador Nave-Bayes + Adaboost con el descriptor HOG con la variación Ludwig con 20 clasificadores débiles.	57
Figura 44 Curva DET para el clasificador Nave-Bayes + Adaboost con el descriptor HOG con la variación Gao con 3 clasificadores débiles.....	58
Figura 45 Curva DET para el clasificador Nave-Bayes + Adaboost con el descriptor HOG con la variación Gao con 6 clasificadores débiles.....	59
Figura 46 Curva DET para el clasificador Nave-Bayes + Adaboost con el descriptor HOG con la variación Gao con 9 clasificadores débiles.....	59
Figura 47 Curva DET para el clasificador Nave-Bayes + Adaboost con el descriptor HOG con la variación Gao con 12 clasificadores débiles.....	60
Figura 48 Curva DET para el clasificador Nave-Bayes + Adaboost con el descriptor HOG con la variación Gao con 20 clasificadores débiles.....	60

Figura 49 Resultados del Detector donde (a) es el fotograma original, (b) son las ROIs generadas en el fotograma y (c) es el resultado final del en donde se excluyen las ROIs que no contiene un peatón mediante la etapa de clasificación.....	62
Figura 50 Resultados del Detector donde (a) es el fotograma original, (b) son las ROIs generadas en el fotograma y (c) es el resultado final del en donde se excluyen las ROIs que no contiene un peatón mediante la etapa de clasificación.....	64
Figura 51 Fotogramas del video 1 el cual se usará para evaluar el seguimiento de un peatón.	65
Figura 52 Fotograma del video ya realizado el seguimiento del peatón.....	66
Figura 53 Resultados del seguimiento realizado de peatón del video 1 en una escena sintética con una sola persona.	66
Figura 54 Fotogramas del video 2 el cual se usará para evaluar el seguimiento de un peatón.	67
Figura 55 Resultados del seguimiento realizado de peatón del video 2 en una escena sintética con una sola persona.	67
Figura 56 Fotogramas del video 3 el cual se usará para evaluar el seguimiento de un peatón.	68
Figura 57 Resultados del seguimiento realizado de peatón del video 3 en una escena sintética con una sola persona.	68
Figura 58 Fotogramas del video 4 el cual se usará para evaluar el seguimiento de un peatón.	69
Figura 59 Resultados del seguimiento realizado de peatón del video 4 en una escena sintética con una sola persona.	69
Figura 60 Fotogramas del video 5 el cual se usara para evaluar el seguimiento de un peatón.	70
Figura 61 Resultados del seguimiento realizado de peatón del video 5 en una escena sintética con una sola persona.	70

Figura 62 Curvas FPPI del seguimiento del peatón del (a) video 1, (b) video 2, (c) video 3, (d) video 4 y (e) video 5. 72

RESUMEN

En este proyecto de titulación se implementó un algoritmo para la detección y el seguimiento de peatones durante el día, usando visión por computador. Esta propuesta consta de dos partes, un módulo de clasificación y un módulo de seguimiento. Para el clasificador se usó una nueva versión del descriptor HOG, para la generación del vector de características, luego se entrenó el algoritmo Adaboost como clasificador fuerte, junto con Naive Bayes como clasificador débil. En la etapa de seguimiento se utilizó el filtro de Kalman, para el seguimiento de un peatón presente en la escena. El clasificador fue entrenado y evaluado sobre las bases de datos: Daimler (Daimler, 2013), INRIA (INRIA, 2005), P_T_HI (Flores, Robayo, & Saa, 2015), MIT (MIT, s.f.), CVC-03 (Elektra, 2010). Para la fase de entrenamiento se usaron 39000 imágenes de no peatones y 21000 imágenes de peatones, para la validación se usaron 19974 imágenes de peatones y 37274 imágenes de no peatones, obteniendo una exactitud del 85,2% y una sensibilidad del 93,76%. En la evaluación del filtro de Kalman se utilizó cinco videos formando un total de 3239 fotogramas, obteniendo una tasa de fallas promedio en escala logarítmica MR(%) del 40.35%.

Palabras Clave

- **HOG**
- **ADABOOST**
- **NAIVE BAYES**
- **FILTRO DE KALMAN**

ABSTRACT

In this graduation project is developed an algorithm for the pedestrian detection and tracking in the day using computer vision. This approach consist in two parts, the classification and the tracking modules. For the classifier was used a new HOG descriptor version, for the feature vector, then the Adaboost algorithm was trained as a hard classifier with the Naive Bayes as weak classifier. In the tracking stage the Kalman filtre with which it is the pedestrian tracking present at the scene. The classifier was trained and evaluated on the next databases: Daimler (Daimler, 2013), INRIA (INRIA, 2005), P_T_HI (Flores, Robayo, & Saa, 2015), MIT (MIT, s.f.), CVC-03 (Elektra, 2010). To the training stage was used 39000 images with pedestrian and 21000 without pedestrian, for validation 19974 and 37274 images, getting a accuracy of 85,2% and a sensibility of 93,76%. In the evaluation of the Kalman filter, five videos were used, forming a total of 3239 frames, obtaining an miss error MR(%) of 40.35%.

Keywords:

- **HOG**
- **ADABOOST**
- **NAIVE BAYES**
- **FILTRO DE KALMAN**

CAPÍTULO I

1. INTRODUCCIÓN

1.1. Antecedentes

En los últimos años, la propiedad de vehículos está en aumento debido al desarrollo de la economía y al aumento de la población (El Blog Salmón, 2016). Pero hay un importante sector de la población que se ve afectado debido a los accidentes de tránsito, por lo cual se está desarrollando tecnología que busca hacer la conducción más segura, a través, de los Sistemas de Asistencia al Conductor (ADAS, por sus siglas en inglés) (Li, Sun, Liu, & Wang, 2015).

Los Sistemas Avanzados de Asistencia al Conductor ADAS, son sistemas inteligentes diseñados principalmente para mejorar la seguridad vial en la conducción (MAPFRE, s.f.). Algunos ejemplos de tales sistemas incluyen sistemas de protección de peatones (CEA, s.f.), control de cruce (Safelita, 2016), sistemas de comunicación vehicular (Safelita, 2016), sistemas de navegación (Safelita, 2016), información del tráfico (Safelita, 2016) (Mammeri, Boukerche, & Almulla, 2013).

Sin embargo, los sistemas actuales están todavía lejos de ser perfectos. Esto se debe principalmente a algunos desafíos y problemas, como la resolución de la cámara, condiciones de baja iluminación, distancia, oclusiones (Mammeri, Boukerche, & Almulla, 2013).

Teniendo en cuenta los retos y desafíos que todavía se tiene dentro de esta temática, en esta investigación se propone un algoritmo de detección y seguimiento de peatones, durante el día, para aplicaciones en vehículos inteligentes.

1.2. Sistemas inteligentes de transporte

Los sistemas inteligentes de transporte (SIT) se pueden definir como un conjunto de aplicaciones avanzadas dentro de las tecnologías de la información, electrónica y de

comunicaciones como se observa en la **Figura 1**, desde un punto de vista social, económico y medioambiental, están destinadas a mejorar la movilidad, seguridad y productividad del sector transporte, optimizando la utilización de las infraestructuras existentes, aumentando la eficiencia en el consumo de energía y mejorando la capacidad de sus sistemas (Quintana & Acurio, 2016).

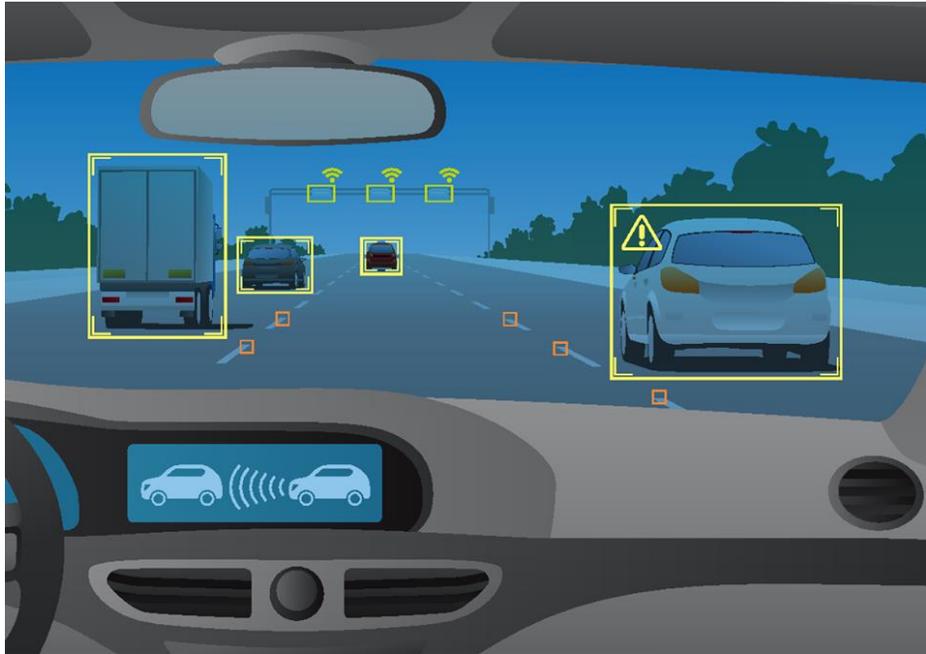


Figura 1 Ejemplo de un sistema inteligente de transporte.

Fuente (TRACK, 2017)

Los Sistemas Inteligentes de Transporte (SIT) surgen en la década de los años 90 como alternativa sostenible al problema generado por la creciente demanda de movilidad, especialmente en el ámbito urbano e interurbano. De esta manera, frente a las estrategias tradicionales -que pasan por un incremento de infraestructuras viarias y vehículos que pudieran conducir a niveles de insostenibilidad económica, espacial y medioambiental. Esto es, una apuesta por incrementar la movilidad sobre la base de mejorar la eficiencia del transporte y proveer seguridad a los usuarios (Seguí & Martínez, 2004).

1.2.1. Clasificación de los sistemas inteligentes de transporte

Existen diversos sistemas tecnológicos aplicados al sector que están enfocados en mejorar su eficiencia, algunos de ellos son: cámaras de video para detectar accidentes, tableros de mensajes dinámicos de información vial, dispositivos de rastreo vehicular para calcular tiempos de recorrido, sistemas de pago electrónico (peajes, pagos de tarifa de transporte público), centros de gestión de tránsito y sistemas inteligentes de semáforos (Quintana & Acurio, 2016).

Según su funcionalidad los SIT se clasifican en 6 categorías (Brief introduction to Intelligent Transportation System, ITS, s.f.):

- **Sistemas avanzados de gestión de tráfico:** Integra varios subsistemas que responden en tiempo real a las condiciones cambiantes del tráfico mediante una sola interface que provee información sobre este, además predice el estado del tráfico para una eficiente planificación.
- **Sistemas avanzados de información al viajero:** Permite al viajero acceder a información que lo asisten en el proceso de toma de decisión respecto a qué modo de transporte elegir, tiempo de viaje, elección de rutas, evasión de congestionamiento.
- **Sistemas avanzados de control vehicular y seguridad:** Ayuda al conductor a tener un mejor control vehicular para evitar accidentes, incluye sistemas de alerta de pre colisión, sistemas automáticos de frenado o aceleramiento, sistemas de parqueo automático, entre otros.
- **Sistemas avanzados de transporte público:** Utiliza las tres categorías mencionadas anteriormente con el fin de mejorar la calidad del servicio de transporte e incentivar el uso de transporte público.
- **Operaciones de vehículos comerciales:** Al igual que el anterior utiliza las tres primeras clasificaciones inicialmente mencionadas en operación de vehículos comerciales con el objetivo de mejorar la eficiencia y seguridad.

- **Sistemas avanzados de asistencia a la conducción:** Integración de varias tecnologías que apoyan al conductor en el difícil proceso de la conducción.

1.3. Accidentes de tránsito

Según el diccionario de la Real Academia Española, un accidente se define como un suceso eventual o acción de que resulta daño involuntario para las personas o las cosas (Los accidentes de tránsito son un problema socioeconómico, s.f.).

Cada año, 1,25 millones de personas en el mundo mueren debido a los accidentes de tránsito, cada día cerca de 3500 personas fallecen en las vías, decenas de millones sufren heridas o discapacidades. Entre los usuarios más vulnerables a los accidentes se encuentran peatones y ciclistas, según el informe sobre la situación mundial de la seguridad vial 2015 (Organización Mundial de la Salud, s.f.).

1.3.1. Accidentes de tránsito a nivel mundial

Cada año se pierden aproximadamente 1,25 millones de vidas como consecuencia de los accidentes de tránsito. Entre 20 millones y 50 millones de personas sufren traumatismos no mortales, y muchos de esos traumatismos provocan una discapacidad. Los accidentes de tránsito cuestan a la mayoría de los países el 3% de su PIB. (OMS, 2017)

Las lesiones causadas por los accidentes de tránsito, ocasionan pérdidas económicas considerables para las personas, sus familias y los países en su conjunto. Estas pérdidas son consecuencia de los costos del tratamiento y de la pérdida de productividad de las personas que mueren o quedan discapacitadas por sus lesiones, y del tiempo de trabajo o estudio que los familiares de los lesionados deben distraer para atenderlos (OMS, 2017).

1.3.2. Accidentes de tránsito en Latino América

De acuerdo con el Boletín FAL N° 342 de la Comisión Económica para América Latina y el Caribe (CEPAL), la tasa de fatalidad por siniestros viales en la región se incrementó

20% en la primera década del presente siglo, pasando de 14,75 personas por cada 100.000 habitantes en el año 2000 a 17,68 personas en 2010 (CEPAL, 2015).

Según el Plan de Acción mundial para la década se establecieron cinco pilares que buscan promover el desarrollo y la coordinación de acciones para reducir la mortalidad por siniestros viales en el ámbito local, nacional y mundial. En el estudio de la CEPAL se analiza el desempeño de América Latina y el Caribe en estos cinco pilares durante los primeros años del decenio de acción y se presentan los desafíos pendientes para la región en materia de seguridad vial.

Los cinco pilares tienen relación con la gestión de la seguridad vial, las vías de tránsito y movilidad, vehículos más seguros, los usuarios de las vías y la respuesta tras los accidentes (CEPAL, 2015).

La inseguridad vial en Latinoamérica provoca cerca de 130.000 muertes al año, unos 6 millones de heridos y centenares de miles de personas con alguna discapacidad. En materia de seguridad vial, América Latina sigue ocupando el primer lugar en el triste ranking mundial de las regiones con las tasas de mortalidad más altas por accidentes de tráfico (Índice de accidentes de tránsito en América Latina, 2015).

1.3.3. Accidentes de tránsito en el Ecuador

Durante el año 2015 los accidentes de tránsito en Ecuador registran disminuciones de un 7,6%, respecto al año anterior al pasar de 38658 en el año 2014 a 35706 accidentes de tránsito en el año 2015. En la **Figura 2** se muestra que durante el periodo 2006-2015, los accidentes de tránsito en Ecuador presentan un incremento promedio anual de 7,5% al pasar de cerca de 18573 en el año 2006 a 35706 accidentes de tránsito en el año 2015 (CAN, 2016).

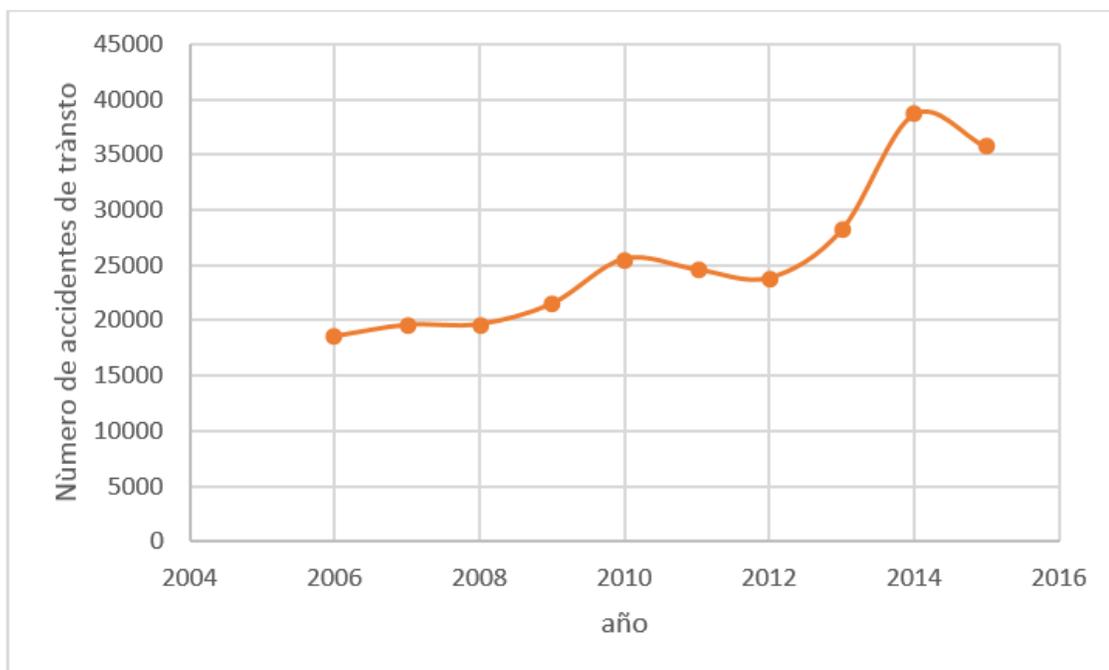


Figura 2 Evolución de accidentes de tránsito en Ecuador, 2006-2015.

Según las clases de accidentes de tránsito en el Ecuador los mayores accidentes acontecidos en el 2015 fueron: choques con los cuales totalizaron 15976 accidentes, le sigue otros con 12726 accidentes, atropellos con 5140 accidentes, volcadura con 1054 accidentes y en menor cantidad la caída de pasajeros con 810 accidentes. Según la **Figura 3** los choques fueron la clase de accidentes de tránsito que concentro el 45% del total de accidentes de tránsito en el Ecuador en al año 2015 (CAN, 2016).

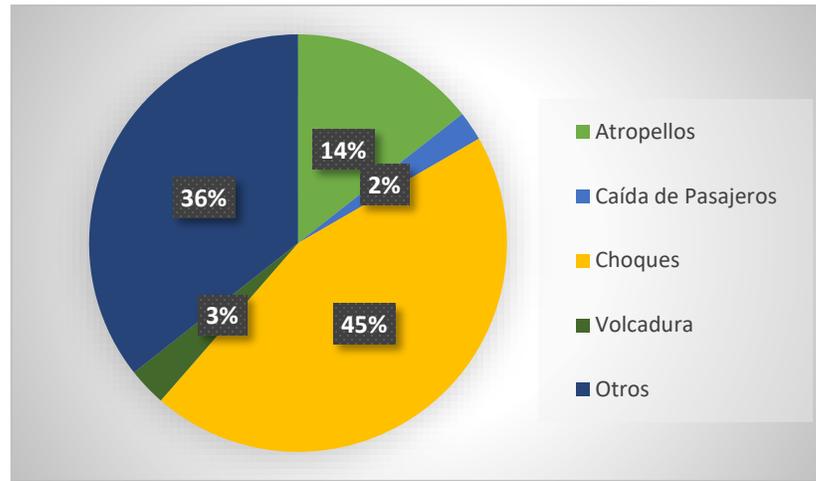


Figura 3 Accidentes de tránsito en el Ecuador según clase, 2015.

En el año 2015, el Ecuador registró 25234 personas heridas y 2138 personas muertas en accidentes de tránsito, representando una disminución de 8,8% y 7,9% respectivamente. En la **Figura 4** se muestra las estadísticas en el periodo de 2006-2015 (CAN, 2016).

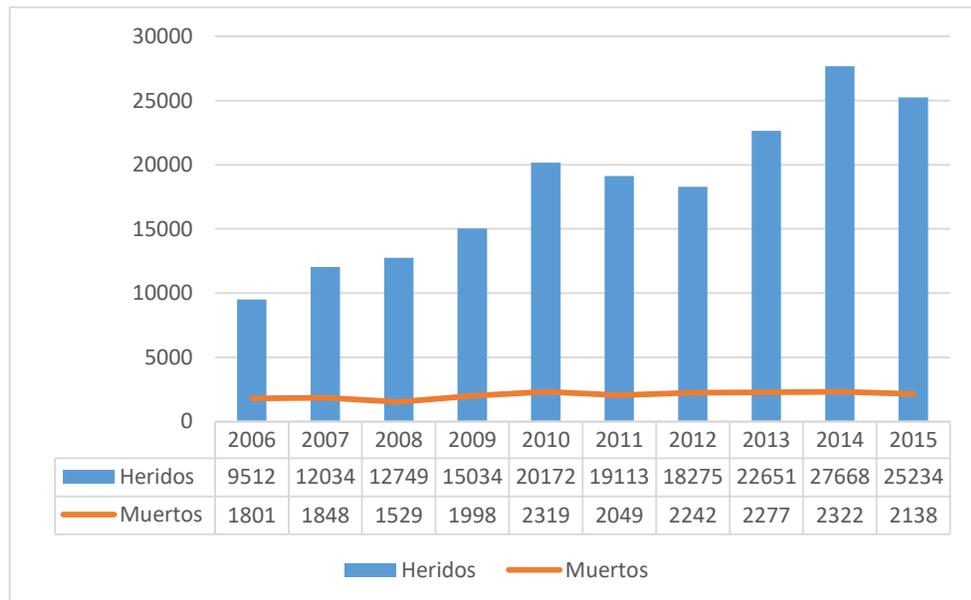


Figura 4 Evaluación de los heridos y muertos en accidentes de tránsito en Ecuador, 2006-2015.

1.4. Justificación e Importancia

En la actualidad está comprobado que existe una mayor desconcentración de los peatones y conductores, por causa de tecnología y al no respetar las leyes de tránsito. Según la Agencia Nacional de Tránsito del Ecuador con datos del 2016 se produjeron 181 fallecidos por imprudencia del peatón por las siguientes causas: por no transitar por las aceras o zonas de seguridad destinadas para el efecto, 25 fallecidos por peatón que cruza la calzada sin respetar la señalización existente (semáforos o señales manuales) y 10 fallecidos por transitar bajo influencia del alcohol, sustancia estupefacientes o psicotrópicas y/o medicamentos, con un porcentaje del 8,47%, 1,17% y 0,47% respectivamente (Agencia Nacional de Tránsito, 2015).

Otra causa principal de accidentes es conducir desatento y no poder anticiparse ante una posible colisión con un peatón, según los datos de la Agencia Nacional de Tránsito con datos de enero- octubre de 2015 se produjeron diversos siniestros por mala actitud del conductor siendo las causas principal: no respetar las señales reglamentarias de tránsito (pare, ceda el paso, luz roja del semáforo), por conducir desatento a las condiciones de tránsito (pantallas de video, comida, maquillaje o cualquier otro elemento distractor) con un 13,75% y un 12,01% de ocurrencia respectivamente (Agencia Nacional de Tránsito, 2015).

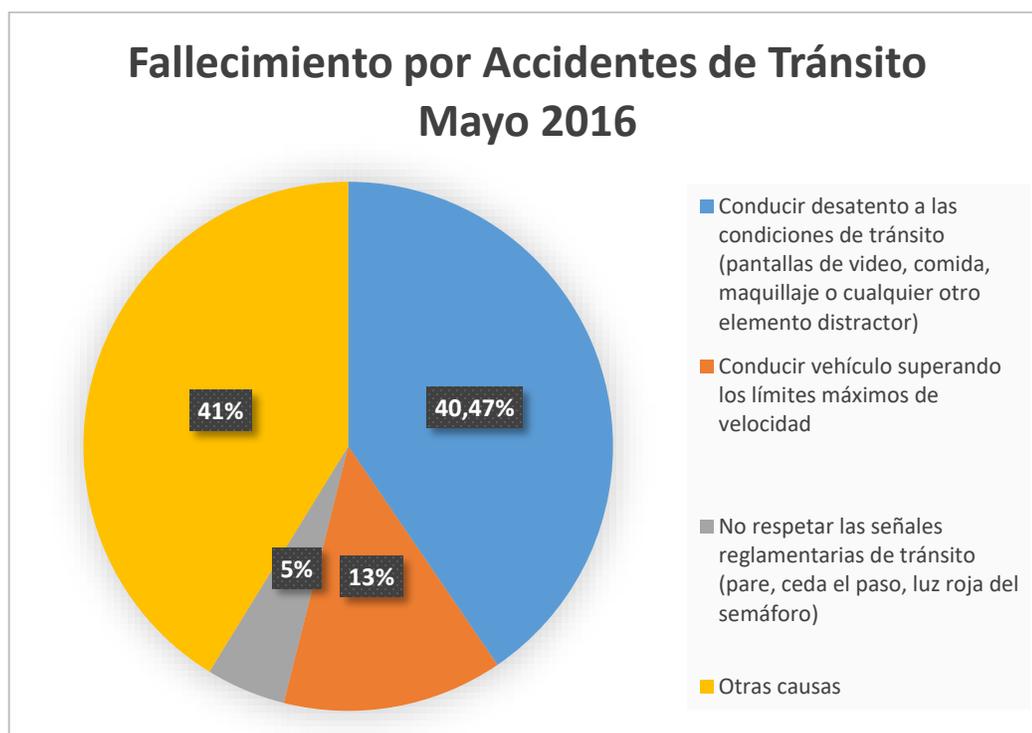


Figura 5 Fallecimiento por accidentes de tránsito provocados por el conductor Mayo 2016.

Fuente: (Agencia Nacional de Tránsito, 2016)

En el caso de fallecimientos por accidentes de tránsito a octubre de 2015 se tienen que las principales causas de estos accidentes son: conducir desatento a las condiciones de tránsito (pantallas de video, comida, maquillaje o cualquier otro elemento distractor); conducir vehículo superando los límites máximos de velocidad; no respetar las señales reglamentarias de tránsito (pare, ceda el paso, luz roja del semáforo) con porcentajes de ocurrencia de 40,47%, 13,45% y 4,86% respectivamente (Agencia Nacional de Tránsito, 2016).

Esta investigación se presenta con la finalidad de que en un futuro cercano se pueda mejorar la seguridad vial en el Ecuador, mediante la aplicación de sistemas de asistencia al conductor, se podría predecir una posible colisión con un peatón y advertir al conductor mediante una alarma sonora. De esta manera se puede crear un sistema

automático para la asistencia en la conducción, al ser un tema de investigación muy amplio se podrá incentivar a realizar futuras trabajos para complementar esta investigación.

1.5. Alcance del proyecto

En el presente trabajo de investigación, se plantea el desarrollo de un algoritmo automático para la detección de peatones, durante el día, usando técnicas de inteligencia artificial y visión por computador.

Para la detección de personas en ambientes urbanos se deben cumplir las siguientes condiciones: el peatón se pueda visualizar completamente en una zona restringida de la visión de la imagen, el peatón debe ser visualizado en condiciones diurnas en ambientes urbanos, por último el peatón será detectado a una distancia de entre 4 a 13 metros.

En este contexto se desarrollará un algoritmo de clasificación de peatones, usando el algoritmo AdaBoost como clasificador fuerte y Naive-Bayes como clasificador débil, (Kumar, Pavan, & Deekshitulu, 2012), usando una nueva versión del descriptor HOG (Flores, Robayo, & Saa, 2015).

La siguiente parte del proyecto se centra en el desarrollo de un algoritmo de seguimiento y estimación de la trayectoria de un peatón, tomando como referencia de un vehículo estático para lo cual se ha utilizado el filtro de Kalman, permitiendo el funcionamiento en tiempo real.

Para el desarrollo de los experimentos se han utilizado las principales bases de datos de peatones presentes en el estado del arte y que sirven de referencia para verificar la validez de este tipo de sistemas.

Posteriormente, se han desarrollado varios experimentos en condiciones reales de conducción en varias calles de las ciudades de Quito y Sangolquí. Sobre esta información se han construido índices de calidad para verificar el desempeño del sistema.

1.6. Objetivos

1.6.1. Objetivo general

Desarrollar un algoritmo automático para la detección, seguimiento y estimación de la trayectoria de peatones en ambientes urbanos en el espectro visible, para aplicación en vehículos inteligentes.

1.6.2. Objetivos específicos

- Desarrollar un estudio del estado del arte de algoritmos matemáticos para en la detección de peatones en el espectro visible.
- Desarrollar un algoritmo de detección de personas basados en algoritmos de Adaboost y Naive-Bayes.
- Desarrollar un algoritmo de seguimiento y estimación de la trayectoria de una persona usando filtro de Kalman.
- Integrar en un solo sistema la detección y seguimiento de personas, para estimar su trayectoria.
- Desarrollo experimental y análisis de resultados.

CAPÍTULO II

2. ESTADO DEL ARTE

2.1. Introducción

La detección de peatones es un campo importante dentro de la visión por computadora, porque es ampliamente utilizado en aplicaciones de video-vigilancia (Fei, Yun, Jun, & Hua, 2014), vehículos inteligentes (Fickenscher, Reinhart, Hannig, & Teich, 2017), etc. Sin embargo, debido a las grandes variaciones en la postura y la vestimenta de los peatones, así como el fondo e iluminación variable, sigue siendo una tarea desafiante (Zheng & Chen, 2012), (Huo, Liu, & Shang, 2016).

En los últimos años, con el desarrollo de algoritmos machine learning enfocados a la clasificación de peatones han demostrado alcanzar resultados exitosos. Estos enfoques incluyen principalmente tres puntos clave: generación de ROIs, extracción de características y clasificación.

El filtro de Kalman ayuda a los algoritmos de detección de peatones cuando el clasificador tiene un falso negativo dando la posición estimada en el siguiente paso del tiempo ($t+1$) mejorando la precisión del seguimiento del peatón (Ken & Gyu, 2013).

2.2. Clasificación de Peatones

El estudio de la clasificación de personas ha tenido una gran evolución a partir del clasificador de Viola (Viola & Jones, 2004), Una de las variantes para el rendimiento del clasificador es el tipo de características que se utiliza para describir una región de interés (ROI) de una imagen para las cuales se ha postulado distintos métodos como lo son HOG, gradiente, Haar, HOG+Color, Pixelsls, etc.

En la **Tabla 1** se presenta el desempeño de varios clasificadores de peatones los cuales están evaluados por la tasa de fallas promedio en escala logarítmica MR(%) (Benenson,

Mathias, & Tuytelaars, 2013), mientras esta medida tienda a cero mejor será el clasificador.

Tabla 1

Evaluación de los clasificadores de personas según la tasa de fallas promedio logarítmica MR.

METODO	Tipo de Clasificador	Tipo de Descriptor	Base de datos de Entrenamiento	MR(%)
VJ (Viola & Jones, 2004)	Adaboost, Cascading Classifiers	Haar	INRIA	94,73
Shapelet (Sabzmeydani & Mori, 2007)	AdaBoost	Gradients	INRIA	91,37
PosInv (Lin & Davis, 2008)	Hierarchical Part-Template Matching	HOG	NE	86,32
LatSvm-V1 (Felzenszwalb, McAllester, & Ramanan, 2008)	SVM	HOG	NE	79,78
ConvNet (Sermanet, Kavukcuoglu, & Chintala, 2013)	Convolutional Network Model	Pixels	INRIA	77,20
FtrMine (Dollar, Tu, & Tao, 2007)	Discrete AdaBoost	HOG+Color	INRIA	74,42
HikSvm (Maji, Berg, & Malik, 2008)	SVM	HOG	INRIA	73,39
HOG (Dalal & Triggs, 2005)	SVM	HOG	INRIA	68,46
MultiFtr (Wojek & Schiele, A Performance Evaluation of Single and multi-feature people detection, 2008)	SVM	HOG+Haar	INRIA	68,26
HogLbp (Wang & Han, 2009)	SVM	HOG+LBP	INRIA	67,77

CONTINÚA 

AFS+Geo (Levi, Silberstein, & Bar-Hillel, 2013)	SVM	Multiple	INRIA	66,76
AFS (Levi, Silberstein, & Bar-Hillel, 2013)	SVM	Multiple	INRIA	65,38
LatSvm-V2 (Felzenszwalb, McAllester, & Ramanan, 2008)	SVM	HOG	INRIA	63,26
Pls (Schwartz, Kembhavi, & Harwood, 2009)	Partial Least Squares	Custom	INRIA	62,10
MLS (Nam, Han, & Han, 2011)	Adaboost + Weighted Fisher Linear Discriminant	HOG	INRIA	61,03
MultiFtr+CSS (Walk, Nikodem, & Schindler, 2010)	MPLBoost + SVM	Many	NE	60,89
FeatSynth (Bar-Hillel, Levi, & Krupka, 2010)	SVM-PFS	Custom	INRIA	60,16
pAUCBoost (Paisitkriangkrai & Shen, 2013)	SVM + Adaboost	HOG+COV	INRIA	59,66
FPDW (Dollár, Belongie, & Perona, The fastest pedestrian detector in the west, 2010)	Fast Multiscale Detection	HOG+LUV	INRIA	57,40
ChnFtrs (Dollár, Tu, & Perona, Integral channel features, 2009)	Boosting	HOG+LUV	INRIA	56,34
CrossTalk (Dollár, Appel, & Kienzle, Crosstalk Cascades for Frame-Rate Pedestrian Detection, 2012)	Crosstalk Cascades	HOG+LUV	INRIA	53,88

CONTINÚA 

DBN–Isol (Ouyang & Wang, A Discriminative Deep Model for Pedestrian Detection with Occlusion Handling, 2012)	Restricted Boltzmann Machine	HOG	INRIA	53,14
ACF (Dollár & Appel, Fast Feature Pyramids for Object Detection, 2014)	Boosted trees	HOG+LUV	INRIA	51,36
RandForest (Marín, Vázquez, & López, 2013)	Random Forest	HOG+LBP	INRIA	51,17
MultiFtr+Motion (Walk, Nikodem, & Schindler, 2010)	MPLBoost + SVM	Many+Flow	INRIA	50,88
SquaresChnFtrs (Benenson, Mathias, & Tuytelaars, 2013)	Adaboost	HOG+LUV	INRIA	50,17
Franken (Mathias, Benenson, & Timofte, 2013)	Adaboost	HOG+LUV	INRIA	48,68
MultiResC (Park, Ramanan, & Fowlkes, Multiresolution models for object detection, 2010)	Multiresolution Models	HOG	Caltech	48,45
Roerei (Benenson, Mathias, & Tuytelaars, 2013)	Adaboost	HOG+LUV	INRIA	48,35
DBN–Mut (Ouyang, Zeng, & Wang, Modeling Mutual Visibility Relationship in Pedestrian Detection, 2013)	Restricted Boltzmann Machine	HOG	Caltech	48,22

CONTINÚA 

MF+Motion+2Ped (Ouyang & Wang, Single-Pedestrian Detection aided by Multi-pedestrian Detection, 2013)	SVM	Many+Flow	INRIA	46,44
MOCO (Chen, Ding, & Xiao, 2013)	latent-SVM	HOG+LBP	Caltech	45,53
MultiSDP (Zeng, Ouyang, & Wnag, 2013)	SVM	HOG+CSS	Caltech	45,39
ACF-Caltech (Dollár & Appel, Fast Feature Pyramids for Object Detection, 2014)	Boosted trees	HOG+LUV	Caltech	44,22
MultiResC+2Ped (Ouyang & Wang, Single-Pedestrian Detection aided by Multi-pedestrian Detection, 2013)	SVM	HOG	Caltech	43,42
WordChannels (Costea & Nedeveschi, 2014)	Boosting	Many	Caltech	42,30
MT-DPM (Yan, Zhang, & Lei, 2013)	SVM	HOG	Caltech	40,54
JointDeep (Ouyang & Wang, Joint deep learning for pedestrian detection, 2013)	SVM	Color+Gradient	Caltech	39,32
SDN (Luo, Tian, & Wang, 2014)		Pixels	Caltech	37,87
MT-DPM+Context (Yan, Zhang, & Lei, 2013)	SVM	HOG	Caltech	37,64
ACF+SDt (Zitnick, Park, & Ramanan, 2013)	SMV	ACF+Flow	Caltech	37,34

CONTINÚA 

SquaresChnFtrs (Benenson, Mathias, & Tuytelaars, 2013)	Adaboost	HOG+LUV	Caltech	34,81
InformedHaar (Zhang & Bauckhage, Informed haar-like features improve, 2014)	LatSvm	HOG+LUV	Caltech	34,60
Katamari-v1 (Zhang, Benenson, & Schiele, Filtered Channel Features for Pedestrian Detection, 2015)	forest learned + Adaboost	HOG+Flow	Caltech	22,49

En la **Figura 6** se observa la evaluación de los diferentes clasificadores según la tasa de fallas promedio en escala logarítmica y sobre qué base de datos fue entrenada y evaluada.

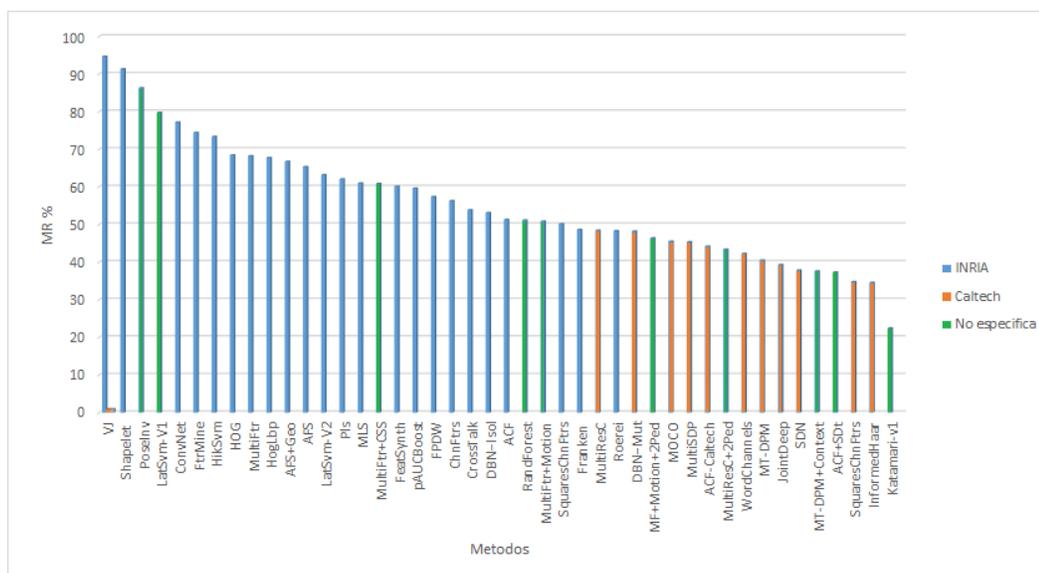


Figura 6 Evaluación grafica de los clasificadores de personas según la tasa de fallas promedio logarítmica (MR).

Fuente: (Benenson, Mathias, & Tuytelaars, 2013)

2.3. Seguimiento y estimación de la trayectoria de un peatón

El filtro de Kalman y el filtro de partículas son dos técnicas ampliamente utilizados en el seguimiento de objetos y en particular en el seguimiento de peatones (Gavrila & Munder, Multi-Cue Pedestrian Detection and Tracking from a Moving Vehicle, 2006) (Fascioli, Broggi, & Bertozzi, 2004), (Philomin, Duraaiswami, & Davis, 2002), (Arndt, Schweiger, & Ritter, 2007), las mismas que se pueden dividir en tres categorías (Owczarek, Baranski, & Strumillo, 2015):

Point Tracking se basa en las posiciones y el movimiento de los puntos que representan el objetivo en cuadros consecutivos. Por lo tanto, el seguimiento del objetivo se puede definir como el problema de encontrar correspondencias de puntos (Liu & Lopes, 2004), (Femmia, Petrone, & Spagnuolo).

Kernel Tracking se basa en la forma o apariencia del objetivo como por ejemplo los peatones (denominado kernel), que está representado por una primitiva geométrica (por ejemplo, un parche rectangular o una elipse). El representante más popular de esta categoría es Mean-Shift (Comaniciu, Ramesh, & Meer, 2002), (Comaniciu & Ramesh, 2002), (Yilmaz, Shafique, & Lobo, 2001) y su modificación, CAMSHIFT (Continuamente adaptativo). Algoritmo Mean-Shift (Bradski, 2002).

Silhouette Tracking se basa en la información codificada dentro de la región de un peatón rastreado que, por lo general, debido a la complejidad de su forma, no se puede describir bien utilizando primitivas geométricas simples (Rosenhahn, Kersting, He, & Smth, 2005), (Hsu, Nguyen, & Wu, 2013).

CAPITULO III

3. CLASIFICACIÓN DE PERSONAS

3.1. Introducción

El proceso de detección de un peatón consiste en la generación de diferentes ROIs (Wu, Geyer, & Rehg, 2011), para su posterior clasificación, la cual determinara si la ROI contiene o no peatón. La **Figura 7** muestra un ejemplo.

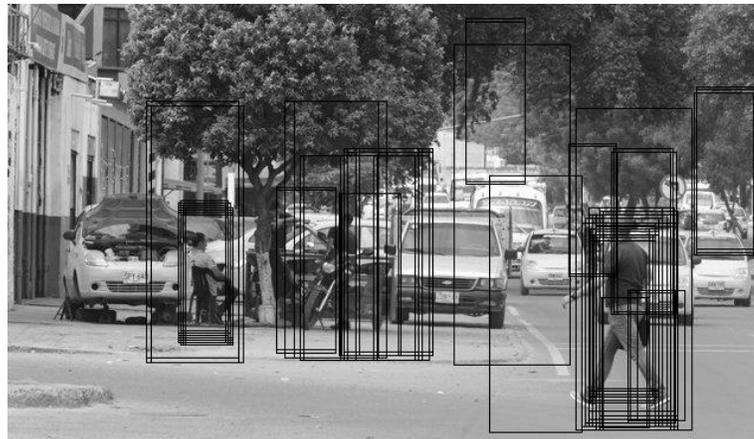


Figura 7 Ejemplo de generación de ROIs para la clasificación de peatones.

La **Figura 8** muestra el esquema propuesto para el diseño del algoritmo de la detección de personas.

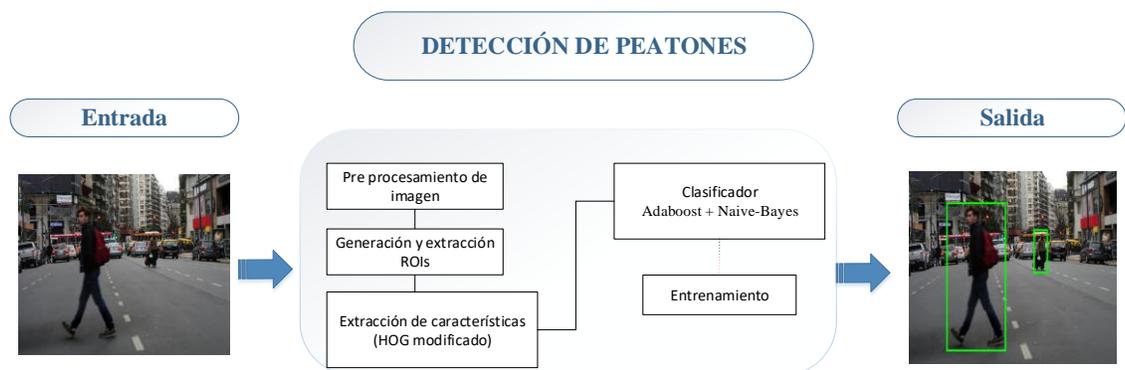


Figura 8 Esquema para la detección de personas durante el día usando visión por computador.

- **Pre-procesamiento:** En esta sub-etapa se procede a cambiar la imagen a color RGB a una imagen de tipo escala de grises con el objetivo de eliminar ruido y contrarrestar efectos ambientales.
- **Generación y extracción ROIs:** Para esta sub-etapa se utilizó el generador de ROIs desarrollado por la universidad de Caltech (Wu, Geyer, & Rehg, 2011).
- **Extracción de características (HOG):** En esta sub-etapa se utiliza el descriptor Histogram of oriented gradients (HOG) permitiendo la transformación de una ROI en un vector con diferentes magnitudes, destacando la información más relevante. Para esta extracción de características se utilizó la versión de (Flores, Robayo, & Saa, 2015)
- **Clasificador Adaboost + Naive- Bayes:** Es un algoritmo machine learning constituido en si por un clasificador fuerte (Adaboost) y de un conjunto de clasificadores débiles (Naive-Bayes) el cual puede identificar la pertenencia a una clase (peatón /no peatón).

En el proceso de detección se pueden encontrar varios factores los cuales pueden provocar un falso positivo o un falso negativo estos se detallan a continuación:

- Presencia de obstáculos que pueden ocluir parcial o totalmente un peatón.
- La existencia de motociclistas o ciclistas en la vía
- Diferentes condiciones meteorológicas del entorno, que producen variación de la iluminación.



(a)



(b)



Figura 9 Principales problemas en la detección de peatones (a) y (b) motociclistas y ciclistas, (c) y (d) variación de condiciones meteorológicas y de iluminación, (e) y (f) personas ocluidas.

3.2. Generación de características usando el descriptor HOG

El cuerpo humano presenta predominantemente una forma vertical y se encuentra compuesto de varias partes. Cada una de ellas tiene una forma particular, por ejemplo, la cabeza y las piernas tienen distinta forma. Tomando en consideración esta información, se divide el cuerpo humano utilizando la estructura de Sashua. (Sashua, Gdalyahu, & Hayun, 2004), ver **Figura 10**, más un conjunto de orientaciones divididas en 4, 6, 8, 10, 12 y 14 para categorizar el ángulo del gradiente θ_G , sobre imágenes de tamaño 18x36 píxeles; a partir de donde se extraerá la mejor opción para calcular el histograma (Flores, Robayo, & Saa, 2015).

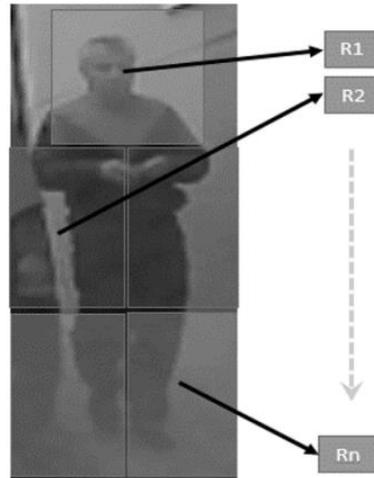


Figura 10 División de partes del cuerpo humano en varias regiones con distintas orientaciones.

Fuente: (Flores, Robayo, & Saa, 2015).

Este método nos proporciona tres variantes de HOG para describir una imagen los cuales son Ludwig. (Ludwig, Delgado, Goncalves, & Nunes, 2009), Xu y Gao (Xu & Gao, 2010). Proporcionando un vector de 81, 126 y 3740 características respectivamente para cada variante.

3.3. Construcción del clasificador débil usando Naive- Bayes

El clasificador Naive-Bayes es un método de aprendizaje supervisado probabilístico basado en la aplicación del teorema de Bayes. Este clasificador matemáticamente queda expresado en la siguiente formula:

$$P(C_k|X_1, \dots, X_n) = \frac{P(C_k)P(X_1, \dots, X_n|C_k)}{P(X_1, \dots, X_n)} \quad (1)$$

Donde:

- C_k representa a la clase $k = 1, 2 \dots, K$. En este caso $K = 2$, para las clases peatón y no-peatón.

- $X_i \in R^n$ representa el vector de características o atributos proporcionado por el descriptor HOG.
- n es el número de características proporcionado por el descriptor HOG.
- $P(C_k|X)$ es la probabilidad posteriori de pertenencia a una clase (peatón /no peatón) dado el vector de atributos.
- $P(C_k)$ es la probabilidad a priori de la clase C_k .
- $P(X|C_k)$ es el verosimilitud del predictor dada la clase

En la práctica sólo importa el numerador, ya que el denominador no depende de C_k y los valores de X_i son datos, por lo que el denominador es, en la práctica, constante. El numerador es equivalente a una probabilidad compuesta:

$$P(C_k|X_1, \dots, X_n)$$

Que puede ser escrita de la siguiente forma, aplicando repetidamente la definición de probabilidad condicional:

$$\begin{aligned} P(C_k|X_1, \dots, X_n) &= P(C_k)P(X_1, \dots, X_n|C_k) \\ &= P(C_k)P(X_1|C_k)P(X_2, \dots, X_n|C_k, X_1) \\ &= P(C_k)P(X_1|C_k)P(X_2|C_k, X_1)P(X_3, \dots, X_n|C_k, X_1, X_2) \\ &= P(C_k)P(X_1|C_k)P(X_2|C_k, X_1)P(X_3|C_k, X_1, X_2)P(X_4, \dots, X_n|C_k, X_1, X_2, X_3) \end{aligned}$$

Y así sucesivamente. Ahora bajo el supuesto de independencia condicional se asume que cada X_i es independiente de cualquier otro X_j para $j \neq i$, esto significa:

$$P(X_i|C, X_j) = P(X_i|C) \quad (2)$$

Por lo tanto la probabilidad condicional se la expresa como:

$$P(C_k|X_1, \dots, X_n) = P(C_k)P(X_1|C_k)P(X_2|C_k)P(X_3|C_k) \dots$$

$$P(C_k|X_1, \dots, X_n) = P(C_k) \prod_{i=1}^n P(X_i|C_k) \quad (3)$$

Dependiendo de la distribución de las características existen diferentes modelos del clasificador Naive Bayes. Para características discretas se recomienda utilizar las distribuciones Multinomiales o de Bernoulli y para características continuas se utiliza una distribución Gauseana en donde la verosimilitud del predictor dada la clase es igual a la **Ecuación 4**. En este caso, el clasificador propuesto tiene características continuas.

$$P(X_i = v|C_k) = \frac{1}{\sqrt{2\pi\sigma_c^2}} e^{-\frac{(v-\mu_c)}{2\sigma_c^2}} \quad (4)$$

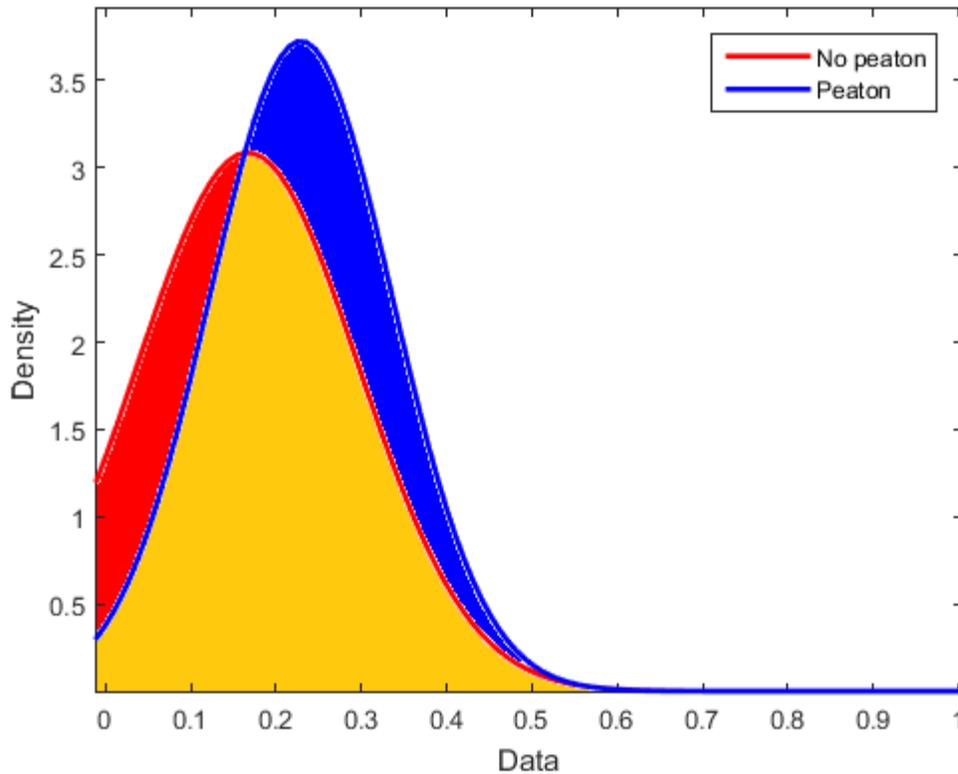


Figura 11 Distribución de datos del descriptor 40 por el método HOG en el caso de Gao (Xu & Gao, 2010).

Para el entrenamiento del algoritmo de Bayes Naive se ha propuesto el siguiente esquema que se observa en la **Figura 12**.

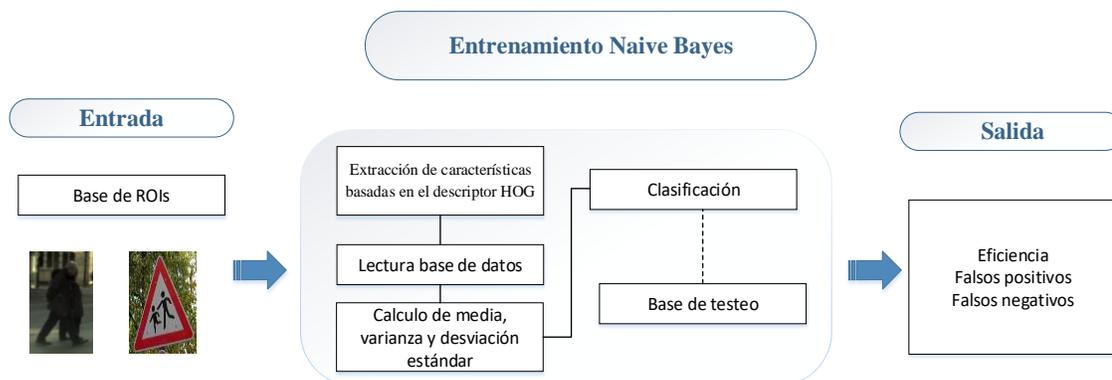


Figura 12 Esquema para la extracción de características HOG para el entrenamiento del algoritmo Naive- Bayes como clasificador débil.

- **Extracción de características basadas en el descriptor HOG:** Esta sub-etapa extrae los descriptores de cada ROI mediante el uso de HOG (Flores, Robayo, & Saa, 2015).
- **Lectura de Base de datos:** Se genera una base etiquetando con +1 o -1 para los casos peatón y no peatón, respectivamente seguido de su vector de características proporcionado por HOG.
- **Calculo de media, varianza y desviación estándar:** Sobre la base anterior se procede a sacar la media, varianza y desviación estándar de cada columna del vector que compone el vector de características de cada clase.
- **Clasificación:** En esta sub-etapa ingresa una base HOG de evaluación para calcular la eficiencia del clasificador. Mediante la ecuación **Ecuación 3** se determina la pertenencia de una clase (peatón/no peatón).

Para el cálculo de la probabilidad previa del descriptor $P(C_k)$ que es la probabilidad de que un peatón $P(C_1)$ y no peatón $P(C_2)$ se encuentre en un fotograma, se la calculo empíricamente con una base de datos de 57248 muestras, con un 35% de muestras positivas y un 65% de muestras negativas, se comparó la variación del valor $P(C_1) = 1 -$

$P(C_2)$, variando la probabilidad de que no exista un peatón en el fotograma $P(C_2)$ y se observó su respuesta en la eficiencia de clasificador, dando como resultado que para el método Ludwig y Gao que utilizan 81 y 121 descriptores respectivamente que una probabilidad de 0.01% da la mayor eficiencia, como se lo observa en la **Figura 13** y **Figura 14** respectivamente para cada método, y en el caso del método Xu la variación de esta probabilidad no afecta la eficiencia del clasificador como se observa en la **Figura 15**.

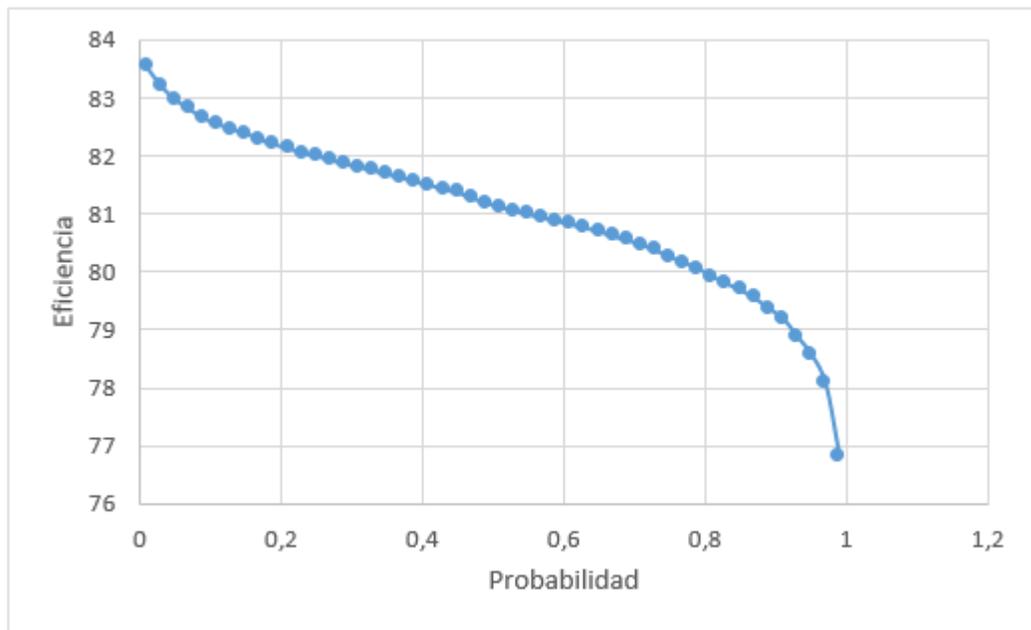
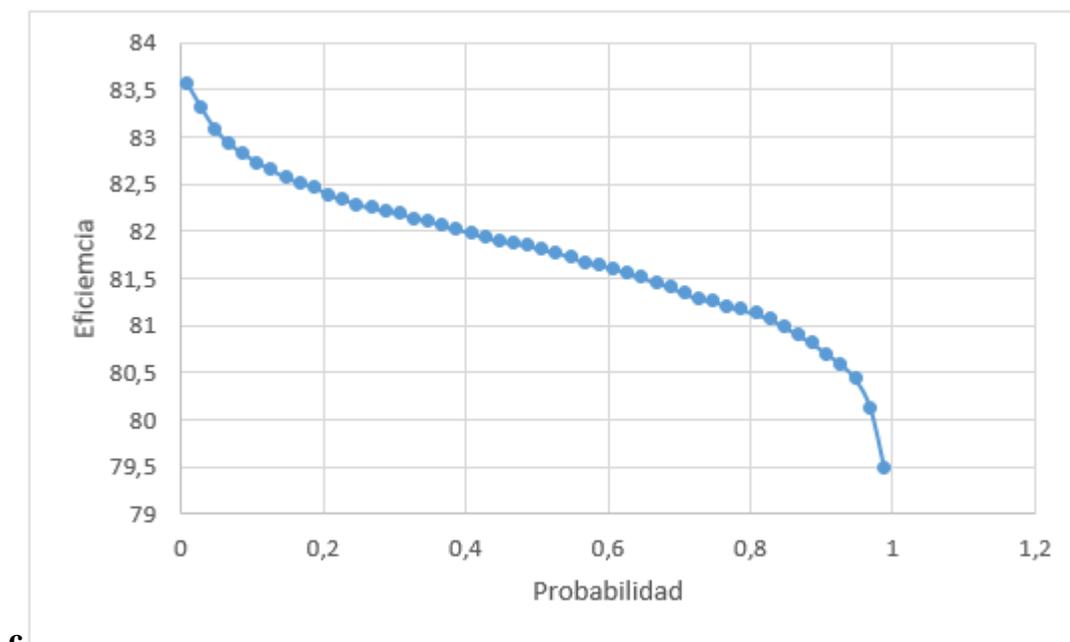


Figura 13 Variación de la probabilidad $P(C_1)$ para el Método Ludwig.



c

Figura 14 Variación de la probabilidad $P(C_1)$ para el Método Gao.

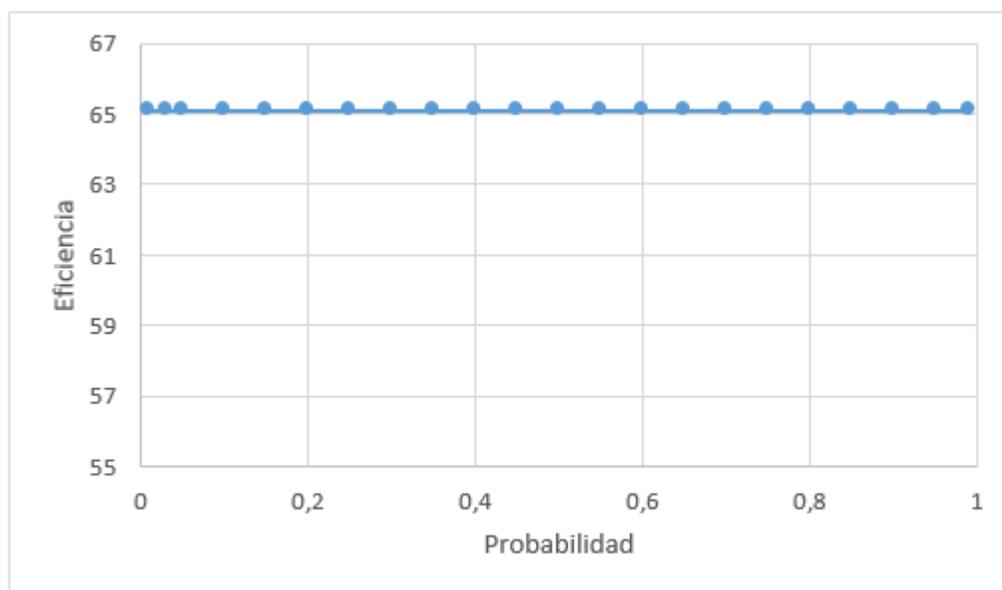


Figura 15 Variación de la probabilidad $P(C_1)$ para el Método Xu.

3.4. Construcción del clasificador fuerte usando Adaboosts y Naive-Bayes

El algoritmo Adaboost se denomina un clasificador fuerte ya que basa su decisión final en la suma de resultados de dos o más clasificadores débiles h_t (*Naive - Bayes*)

multiplicado por un factor de corrección llamada α calculado con (5) y (6), para así mejorar notablemente la eficiencia de clasificador (Korada, Pavan, & Deekshitulu, 2012).

$$F_T(X) = \sum_{t=1}^T \alpha_t h_t(X) \quad (5)$$

$$\alpha_t = \begin{cases} \frac{1}{2} \log\left(\frac{1-\varepsilon}{\varepsilon}\right), & \varepsilon < 0.5 \\ 1, & \varepsilon \geq 0.5 \end{cases} \quad (6)$$

A este algoritmo se lo puede representar gráficamente como se muestra en la [Figura 16](#) e encuentra el origen de la referencia..

En la **Figura 16** se muestra el diagrama de flujo para el entrenamiento de Adaboost con Naive-Bayes, donde se observa que en cada interacción se calculan nuevos pesos relacionados directamente con el clasificador débil (**Korada, Pavan, & Deekshitulu, 2012**).

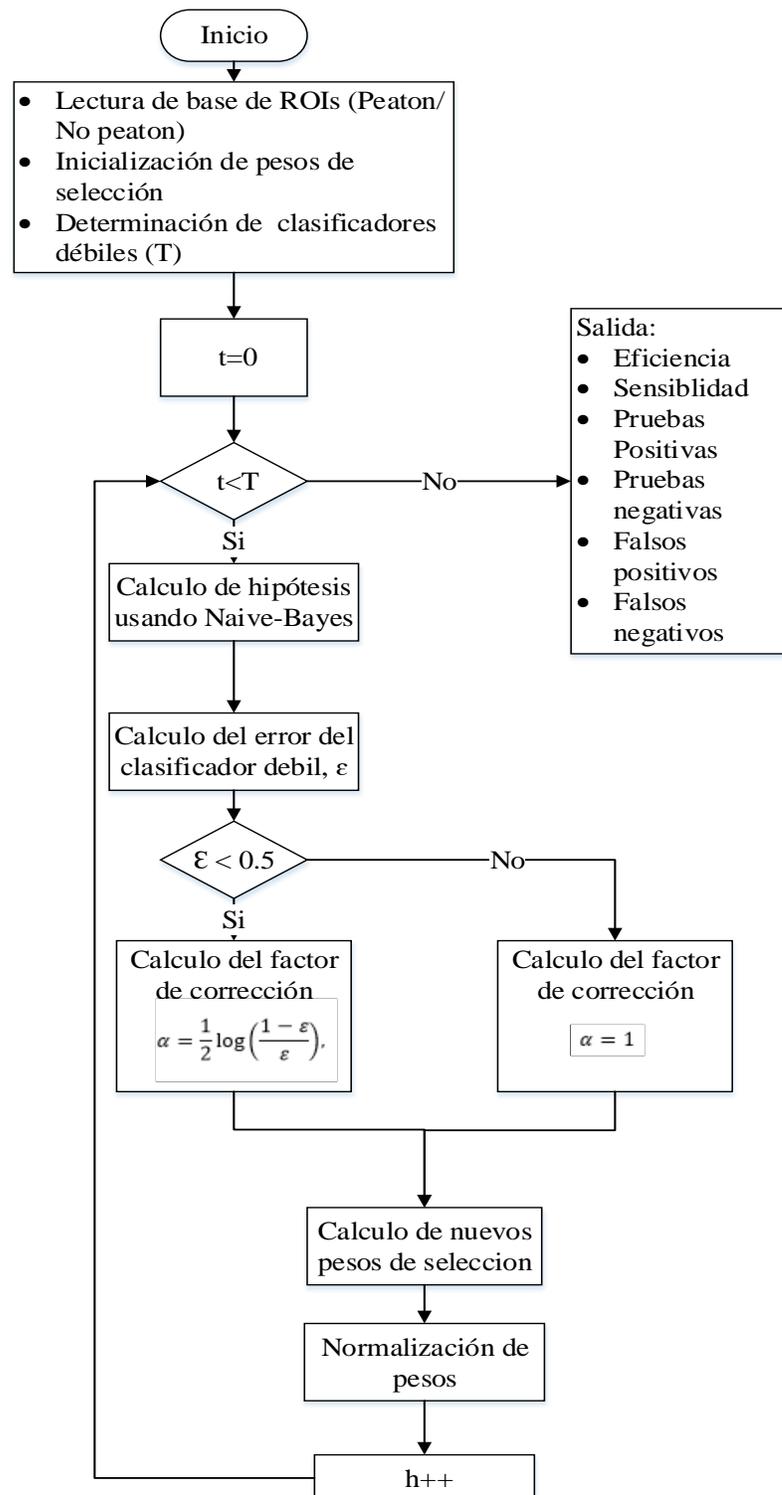


Figura 16 Diagrama de flujo del entrenamiento del clasificador fuerte Adaboost usando el clasificador Naive-Bayes como clasificador débil.

3.5. Resultados parciales

Para evaluar los clasificadores se toma en cuenta la sensibilidad (6) y la exactitud (5) los cuales se obtiene con las siguientes ecuaciones:

$$Exactitud = \frac{T_p + T_n}{T_n + T_p + F_n + F_p} \quad (5)$$

$$Sensibilidad = \frac{T_p + F_n}{T_p} \quad (6)$$

Donde:

T_p son los verdaderos positivos

T_n son los verdaderos negativos

F_n son los falsos negativos

F_p son los falsos positivos

En las **Tabla 2**, **Tabla 3** y **Tabla 4** se muestra la exactitud de los métodos de Ludwig, Gao y Xu respectivamente, estos resultados se obtuvieron realizando pruebas con diferentes bases. En las **Figura 17**, **Figura 18** y **Figura 19** se observa gráficamente la evaluación del clasificador Naive Bayes + Adaboost para los diferentes métodos de extracción de HOG.

Tabla 2

Evaluación de la exactitud del clasificador Adaboost con descriptor HOG con la variación Ludwig.

Evaluación	Número de clasificadores débiles				
	3	6	9	12	20
Daimler	85,24	85,93	86,05	83,89	85,83
P_T_IH	84,24	88,65	87,26	88,82	88,22
MIT	89,94	89,83	96,00	94,91	90,15
INRIA	79,37	78,17	78,86	76,85	79,24
CVC-03	91,06	95,19	93,97	93,35	94,39
Promedio	85,97	87,55	88,43	87,56	87,57

Tabla 3
Evaluación de la exactitud del clasificador Adaboost con descriptor HOG con la variación Gao.

Evaluación	Numero de clasificadores débiles				
	3	6	9	12	20
Daimler	82,60	81,82	81,48	81,20	82,22
P_T_IH	86,89	86,71	86,98	87,38	88,34
MIT	97,40	97,51	96,97	97,73	96,54
INRIA	85,11	83,03	82,71	82,59	82,40
CVC-03	90,84	91,36	93,01	92,57	94,08
Promedio	88,57	88,09	88,23	88,29	88,71

Tabla 4
Evaluación de la exactitud del clasificador Adaboost con descriptor HOG con la variación XU.

Evaluación	Numero de clasificadores débiles				
	3	6	9	12	20
Daimler	51,02	51,02	51,02	51,02	51,02
P_T_IH	96,44	96,44	96,44	96,44	96,44
MIT	28,12	28,12	28,12	28,12	28,12
INRIA	28,58	28,58	28,58	28,58	28,58
CVC-03	87,76	87,76	87,76	87,76	87,76
Promedio	58,39	58,39	58,39	58,39	58,39

En las **Figura 17**, **Figura 18** y **Figura 19** se observa gráficamente la evaluación del clasificador Naive Bayes + Adaboost para los diferentes métodos de HOG.

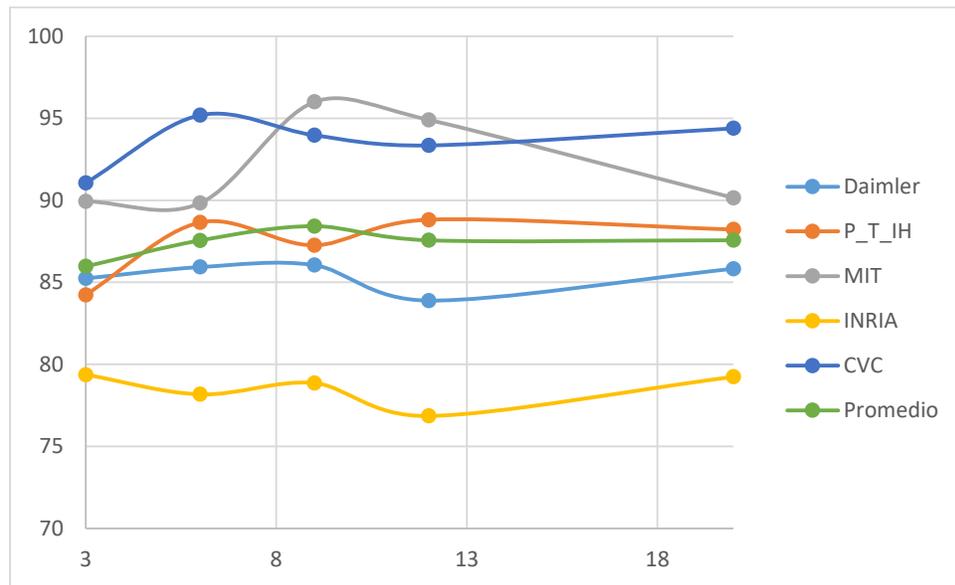


Figura 17 Representación gráfica de la evaluación clasificador Adaboost con descriptor HOG con la variación Ludwig.

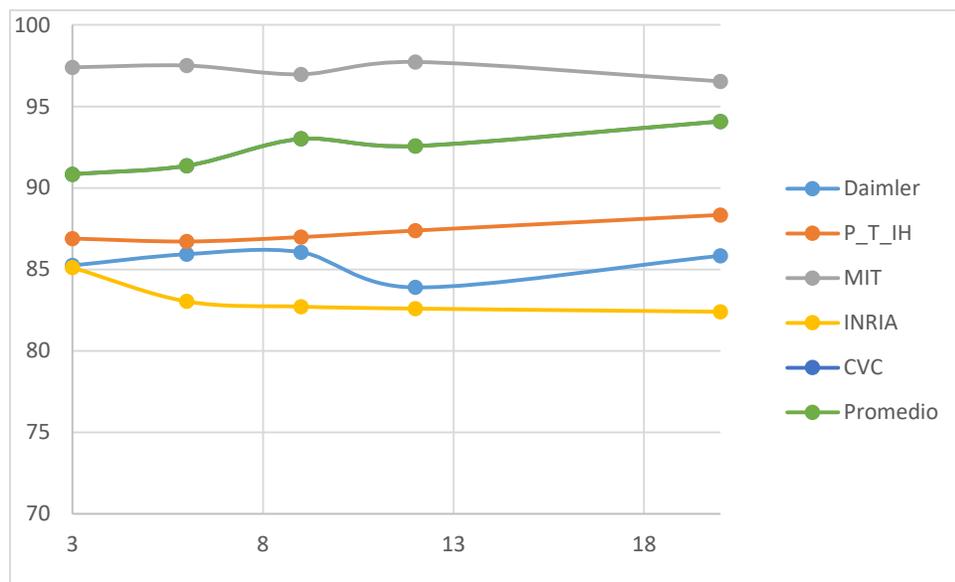


Figura 18 Representación gráfica de la evaluación del clasificador Adaboost con descriptor HOG con la variación Gao.

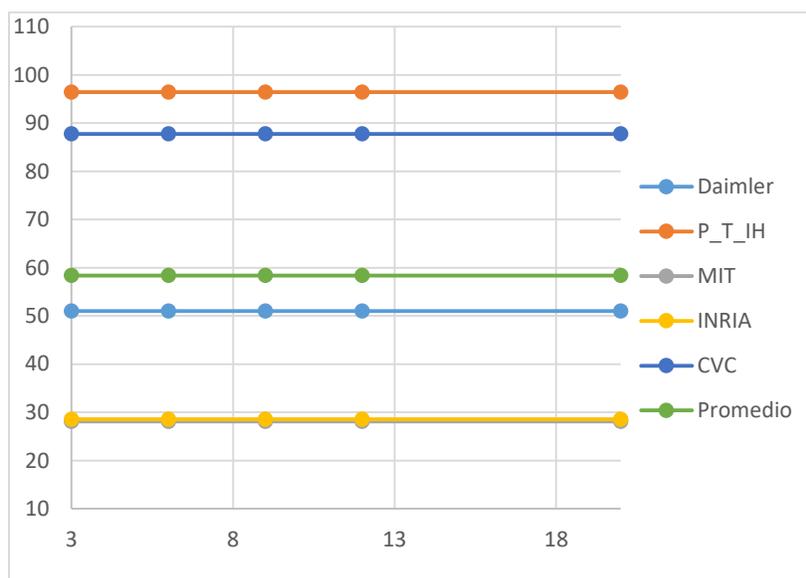


Figura 19 Representación gráfica de la evaluación del clasificador Adaboost con descriptor HOG con la variación Xu.

En la **Figura 19** y **Tabla 4** podemos deducir que para el clasificador Naive Bayes + Adaboost no es aplicable a la variante de extracción de características Xu (**Xu & Gao, 2010**), por los resultados bajos que presentan en la evaluación con las bases de datos Daimler (**Daimler, 2013**), INRIA (**INRIA, 2005**), CVC-03 (**Elektra, 2010**), MIT MIT (**MIT, s.f.**), obteniendo una exactitud promedio de 58,38% y mantenerse constante durante la variación del número de clasificadores débiles en el entrenamiento de Adaboost.

Con los descriptores HOG, con las variantes Ludwig (Ludwig, Delgado, Goncalves, & Nunes, 2009) y Gao (Xu & Gao, 2010) se analiza el otro parámetro de evaluación que es la sensibilidad, presentando sus resultados en la **Tabla 5** y **Tabla 6**. De igual manera los resultados de la sensibilidad se los visualiza gráficamente en la **Figura 20** y **Figura 21**.

Tabla 5

Evaluación sensibilidad del clasificador Adaboost con descriptor HOG con la variación Ludwig.

Evaluación	Numero de clasificadores débiles				
	3	6	9	12	20
Dimler	88,98	85,87	86,57	84,35	86,01
P_T_IH	92,4	93,39	93,87	93,39	93,4
MIT	89,94	89,83	95,99	94,91	90,15
INRIA	94,7	92,31	92,31	88,16	92,40
CVC-03	89,47	89,65	89,91	88,24	88,16
Promedio	91,10	90,21	91,73	89,81	90,02

Tabla 6

Evaluación sensibilidad del clasificador Adaboost Gao.

Evaluación	Numero de clasificadores débiles				
	3	6	9	12	20
Daimler	93,56	90,72	90,82	90,30	91,83
P_T_IH	96,11	97,64	98,58	96,69	96,70
MIT	97,40	97,51	96,96	97,72	97,75
INRIA	92,02	92,93	95,22	93,55	93,64
CVC-03	90,28	91,75	91,38	90,52	90,71
Promedio	93,87	94,11	94,59	93,76	94,13

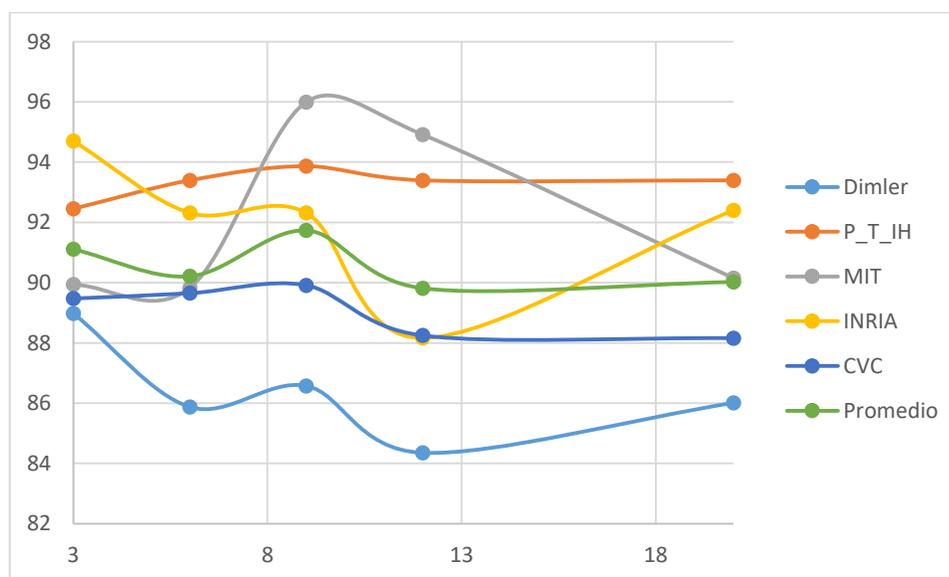


Figura 20 Representación gráfica de la evaluación de la sensibilidad del clasificador Adaboost con descriptor HOG con la variación Ludwig.

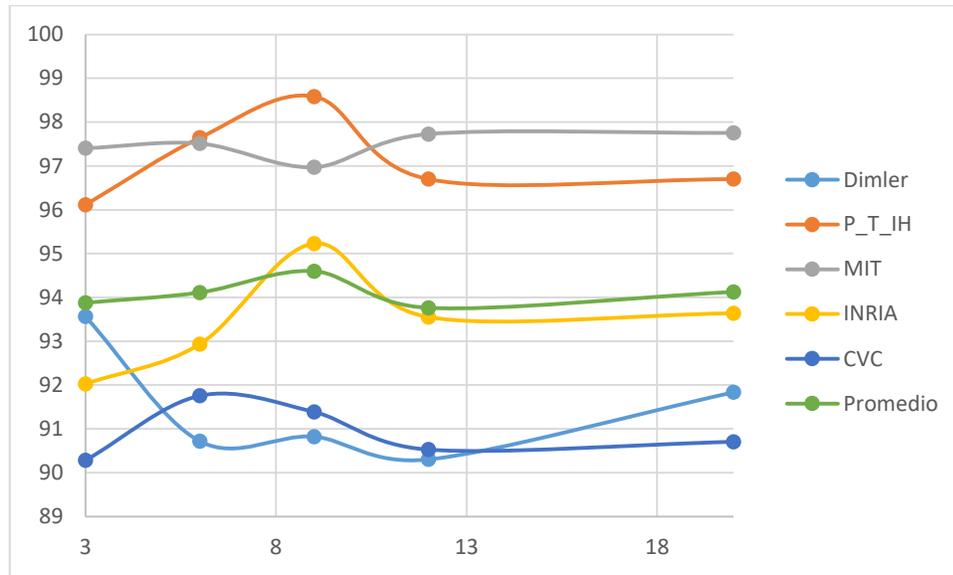


Figura 21 Representación gráfica de la evaluación de la sensibilidad del clasificador Adaboost con descriptor HOG con la variación Gao.

CAPÍTULO IV

4. SEGUIMIENTO Y ESTIMACIÓN DE LA TRAYECTORIA DE UN PEATÓN

4.1 Introducción

El proceso de seguimiento de un peatón consiste en mantener la localización continua del objetivo mientras esté presente en la escena visual. A partir de aquí, estimar la trayectoria para conocer su posible posición futura.

El filtro de Kalman es ampliamente utilizado en visión artificial para el seguimiento de objetos (Xu, Cao, & Li, 2009) (Bertozzi, Broggi, Fascioli, & Tibaldi, 2004) (Armin's Notebook, 2016) (Lui, He, Wei, & Xiang, 2017) (Foytik, Sankaran, & Asari, 2011) (Santosh & Mohan, 2014) (Kim, Muhammad, Wahab, & Soh, 2014) (Thombre & Nirmal, 2009) y en particular, se lo ha utilizado para el seguimiento y estimación de la trayectoria de peatones en sistemas de video-vigilancia (Fei, Yun, Jun, & Hua, 2014) (Collins, Lipton, & Kanade, 2000) (Bagherpour & Cheraghi, 2012) (Marcinkowski, Korzeniewski, & Czyzewski, 2011) (SULIMAN, CRUCERU, & MOLDOVEANU, 2010) (Kaur & Singh, 2014) en sistemas de ayuda a la conducción en vehículos inteligentes (Fickenscher, Reinhart, Hannig, & Teich, 2017) (Sovani, 2017) (Merven, Nicolls, & de Jager) (Houenou, Bonnifait, & Cherfaoui, 2012) (Pranali & Khule, 2016).

El proceso de seguimiento de cualquier objeto, en nuestro caso un peatón en condiciones diurnas implica la utilización de información pasada y presente para poder estimar los cambios futuros del peatón (Foytik, Sankaran, & Asari, 2011).

En este método de predicción, se requiere obligatoriamente un detector de personas, cabe recalcar los problemas del mismo, ya que influyen directamente sobre la predicción del Filtro de Kalman, los cuales podemos observar en la **Figura 22** y se encuentran detallados a continuación:

- Falsas detecciones, debido a la existencia de formas parecidas a las personas el Filtro de Kalman escoge un valor erróneo para la predicción.
- Variación de iluminación en el ambiente, no permite realizar la correcta detección de personas.



Figura 22 Principales problemas del seguimiento y estimación de la trayectoria de peatones; (a) y (b) falsas detecciones, (c) y (d) variación de iluminación.

4.2 Filtro de Kalman aplicado al seguimiento de personas

Este método de predicción requiere obligatoriamente un detector de personas (Wu, Geyer, & Rehg, 2011), por lo tanto en caso de una oclusión del peatón o en caso de un falso negativo del clasificador, el filtro de Kalman predice el movimiento. Por otro lado cuando el detector de personas y el filtro de Kalman se combinan, se tiene una entrada de medición que ingresa a la matriz H mostrada en la **Ecuaciones 11 y 12**. El filtro de Kalman

usa estos datos para actualizar el estado y obtener un vector de estados probable. La ecuación de actualización de estado se muestra en la **Tabla 8**.

La etapa de seguimiento de peatones consta de varias sub etapas que se muestran en la **Figura 23** y se describen a continuación:

- **Inicialización del Filtro de Kalman:** Se realiza la inicialización de las matrices y variables necesarias para el correcto funcionamiento del Filtro de Kalman.
- **Predicción:** Esta sub etapa está encargada de las estimaciones del vector de estados para obtener la estimación en el siguiente paso del tiempo.
- **Corrección:** Es la sub etapa encargada de la retroalimentación del sistema es decir está encargada de las ecuaciones de corrección **Tabla 8**.

En la **Figura 23** se muestra el diagrama de flujo del funcionamiento del Filtro de Kalman con el detector de peatones.

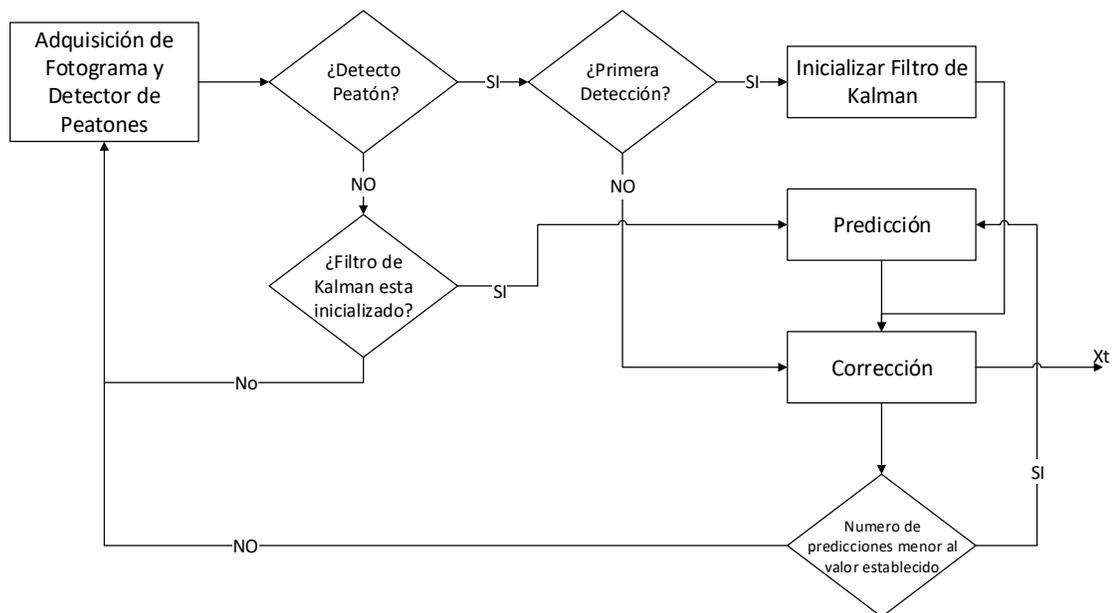


Figura 23 Diagrama de flujo del seguimiento y estimación de la trayectoria de un peatón

El filtro de Kalman está representado por la ecuación lineal (Garcia, Urdiales, Carmona, & Martin, 2016):

$$X_t = A_t x_{t-1} + w_t \quad (7)$$

Donde:

X_t es el vector de estado en el tiempo t, contiene los parámetros de interés del sistema.

A_t es la matriz de transición de estados, encargada de aplicar el efecto a cada parámetro del sistema en el instante t-1 sobre el estado del sistema en el tiempo t.

X_{t-1} es el vector de estado en el tiempo t-1.

W_t es el vector de ruido del proceso que tiene media cero y matriz de varianza-covarianza Q_t . Representa el ruido del proceso causado por el movimiento de los peatones.

Vector de estados:

El vector de estados contiene los parámetros que describen el sistema, para el caso de estimación del estado del peatón se tomó seis parámetros extraídos de las ROI, para los cuales es necesario conocer el sistema de coordenadas de los pixeles de cada fotograma analizado el mismo, que tiene el origen en el extremo superior izquierdo; en la **Figura 24** se muestra el sistema de ejes coordenados y los parámetros de las ROI que se encuentran en el vector de estados.



Figura 24 (a) Eje de coordenadas en cada fotograma y (b) vector de estados en la ROI

El vector de estados esta descrito por:

$$X_t = (x, y, v_x, v_y, w, h) \quad (8)$$

Donde (x, y) es la posición del centro de la ROI, tomando como sistema de referencia los ejes de la **Figura 24**, (v_x, v_y) es la velocidad del centro de la ROI respecto a cada eje de coordenadas, (w, h) en el ancho y la altura de la ROI respectivamente.

Los valores iniciales del vector de estados dependen de la detección, ya que este vector se llena con la posición inicial del peatón y posteriormente se va actualizando con la predicción realizada por el filtro de Kalman (Foytik, Sankaran, & Asari, 2011).

Matriz de transición de estado:

Es una matriz de 6x6 que depende del tiempo es decir que cambia con cada paso de tiempo en este caso Δt es el tiempo de procesamiento entre cada fotograma, también puede tomarse un valor constante de Δt , (Garcia, Urdiales, Carmona, & Martin, 2016) por lo tanto tenemos:

$$A_t = \begin{bmatrix} 1 & 0 & \Delta t & 0 & 0 & 0 \\ 0 & 1 & 0 & \Delta t & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (9)$$

Vector del ruido del proceso:

Contiene los términos de ruido del proceso para cada parámetro del vector de estados, Este vector sigue una distribución normal multi-variable de media cero y la varianza-covarianza Q_t , la misma que varía en el tiempo (Welch & Bishop, 2001) .

$$Q_t = \begin{bmatrix} \sigma_x & 0 & 0 & 0 & 0 & 0 \\ 0 & \sigma_y & 0 & 0 & 0 & 0 \\ 0 & 0 & \sigma_{v_x} & 0 & 0 & 0 \\ 0 & 0 & 0 & \sigma_{v_y} & 0 & 0 \\ 0 & 0 & 0 & 0 & \sigma_w & 0 \\ 0 & 0 & 0 & 0 & 0 & \sigma_h \end{bmatrix} \quad (10)$$

La ecuación de medida establece una relación entre el vector de estados y el vector de observación (obtenido del detector), permitiendo así escoger un valor adecuado para el Filtro de Kalman usando el principio de proyección en perspectiva garantizando así la estimación de la siguiente posición probable del peatón (Xu, Cao, & Li, 2009).

$$Z_t = H_t x_t + v_t \quad (11)$$

Donde:

Z_t Vector de medida.

H_t Matriz de medidas.

v_t Es el vector que contiene los términos de ruido de medición para cada observación, con media cero y matriz de varianza-covarianza R_t .

Matriz de medidas:

En este caso es de dimensiones 4x6 donde relaciona el vector de estados con la medición, esta matriz es actualizada en cada fotograma que se detecte un peatón (Olmeda, 2012), restableciendo las coordenadas del peatón detectado en el eje x (τ_x), en el eje y (τ_y) y su ancho y altura de la ROI (τ_w, τ_h); para que el filtro de Kalman pueda usarla y realizar una actualización del vector de estados (Li, Guo, & Hu, 2010).

$$H = \begin{bmatrix} \tau_x & 0 & 0 & 0 & 0 & 0 \\ 0 & \tau_y & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & \tau_w & 0 \\ 0 & 0 & 0 & 0 & 0 & \tau_h \end{bmatrix} \quad (12)$$

Vector que contiene los términos de ruido de medición:

El ruido de medición es ruido blanco gaussiano medio con varianza-covarianza R_t . La matriz R puede variar en el tiempo (Ramírez, 2003).

$$R_t = \begin{bmatrix} 0.1 & 0 & 0 & 0 \\ 0 & 0.1 & 0 & 0 \\ 0 & 0 & 0.1 & 0 \\ 0 & 0 & 0 & 0.1 \end{bmatrix} \quad (13)$$

Matriz de covarianza:

La matriz de covarianza P_t almacena las varianzas y covarianzas para poder describir completamente las funciones gaussianas, los términos de la diagonal principal son las variaciones asociadas con los términos correspondientes del vector de estados y los términos fuera de la diagonal proporcionan la covarianza entre los términos en el vector de estado (Faragher, 2012). La matriz de la **Ecuación 14** cambia en el tiempo de acuerdo a la ecuación de la etapa de actualización del filtro de Kalman, la inicialización de la matriz está hecha con estos valores:

$$P_t = \begin{bmatrix} 0.1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0.1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0.1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0.1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0.1 \end{bmatrix} \quad (14)$$

Como se ha dicho antes el filtro de Kalman estima el estado del peatón mediante el uso de una retroalimentación, para ejemplificar esto se tiene la **Figura 25** donde se muestran las dos etapas fundamentales que son la actualización en el tiempo, también llamada predicción y la actualización en la medición también llamada corrección.

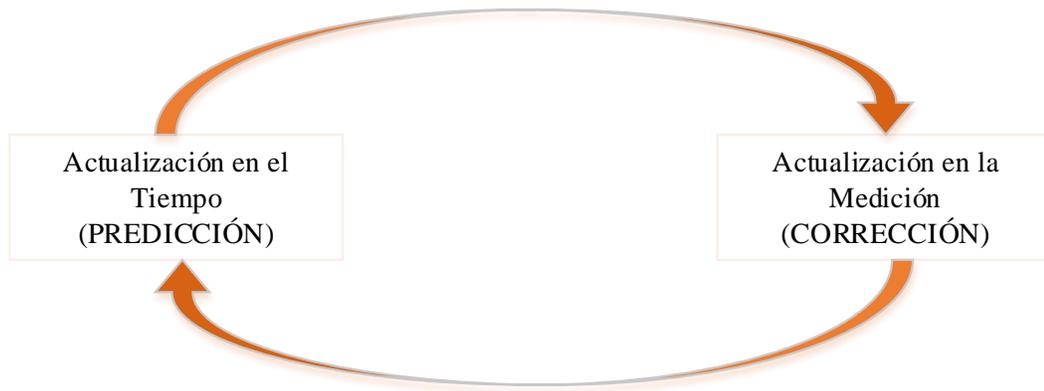


Figura 25 Ciclo del Filtro de Kalman

Como tal las ecuaciones del filtro de Kalman se dividen en dos grupos:

- Ecuaciones de Actualización de tiempo (Predicción)
- Ecuaciones de actualización de la medición (Corrección)

Las ecuaciones de actualización de tiempo son las encargadas de proyectar hacia adelante el estado y la covarianza, las ecuaciones se presentan a continuación en la **Tabla 7** (Welch & Bishop, 2001).

Tabla

7

Ecuaciones de la etapa de predicción del filtro de Kalman

Predicción
Estado Predicho
$X_t = A_t X_{t-1} + B_t u_t$
Error de Covarianza
$P_t = A_t P_{t-1} A_t^T + Q_t$

Las ecuaciones de actualización de la medición son las responsables de la retroalimentación y ajustan la estimación proyectada a una medición real en ese momento, las ecuaciones se presentan a continuación en la **Tabla 8** (Welch & Bishop, 2001).

Tabla 8*Ecuaciones de la etapa de corrección del filtro de Kalman*

Corrección
Ganancia de Kalman
$K_t = P_{t-1} H_t^T (H_t P_{t-1} H_t^T + R_t)^{-1}$
Actualización del estado
$X_t = X_{t-1} + K_t (Z_t - H_t X_{t-1})$
Actualización del error de covarianza
$P_t = P_{t-1} - K_t H_t P_{t-1}$

El primer paso de la etapa de corrección es calcular la ganancia de Kalman K_t el siguiente paso es medir realmente el proceso para obtener Z_t para luego generar la ecuación de estimación del estado, el último paso es estimar la covarianza, como ya se mencionó el filtro de Kalman es recursivo por lo cual facilita la implementación, a continuación se muestra la **Figura 26** donde se encuentra un diagrama completo del funcionamiento del filtro de Kalman.

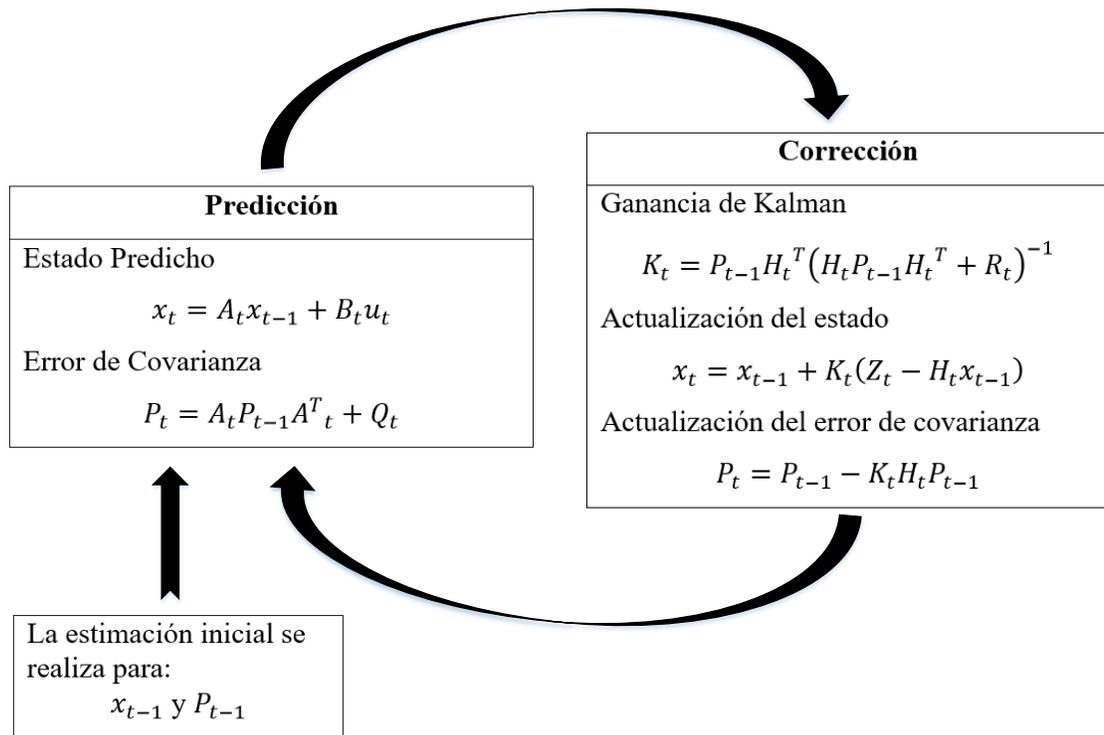


Figura 26 Diagrama del funcionamiento del filtro de Kalman

4.3 Generación de la trayectoria de los peatones

La trayectoria está formada por el conjunto de todas las posiciones por las que pase el peatón al desplazarse.

El detector + filtro de Kalman están centrados en el seguimiento por detección, donde las detecciones están vinculadas con el filtro de Kalman para formar la trayectoria del peatón (Xiang, Alahi, & Savarese).

Para la generación de la trayectoria de un peatón en el plano de dos dimensiones, se toma como referencia el centro del peatón es decir los valores de (x, y) del vector de estados, los valores se van almacenando desde la primera predicción, En la **Figura 27**, se puede observar en color rojo la trayectoria del peatón.



Figura 27 Trayectoria de un peatón

Existen dos sistemas de referencia, el sistema absoluto el cual se considera como un sistema fijo y el sistema relativo el cual no es fijo siempre está en movimiento, si se analiza esto desde el punto de vista de un vehículo en movimiento, este será un sistema relativo y cuando el vehículo esta estacionado será un sistema fijo.

En este proyecto de investigación, se toma el sistema de referencia fijo debido a que en el filtro Kalman no se encuentran introducidas las ecuaciones que describen el movimiento del vehículo.

CAPITULO V

5. PRUEBAS Y RESULTADOS

5.1. Base de datos

Para los resultados parciales se procedió a construir una base de imágenes recolectando bases de datos Daimler (Daimler, 2013), INRIA (INRIA, 2005), P_T_HI (Flores, Robayo, & Saa, 2015), MIT (MIT, s.f.), CVC-03 (Elektra, 2010) especializadas en el estudio de detección de peatones. Llegando a obtener una base de datos como lo detalla la **Tabla 9**, en la **Figura 28** se observa unas muestras de la base de datos.

Tabla 9

Base de datos para el entrenamiento del clasificador Adaboost con Naive-Bayes.

	Peatones	No peatones
Daimler (Daimler, 2013)	14400	15000
MIT (MIT, s.f.)	924	0
CV-C (Elektra, 2010)	2032	15300
P_T_IH (Flores, Robayo, & Saa, 2015)	624	8103
INRIA (INRIA, 2005)	2416	1218
Total	20396	39621



(a)



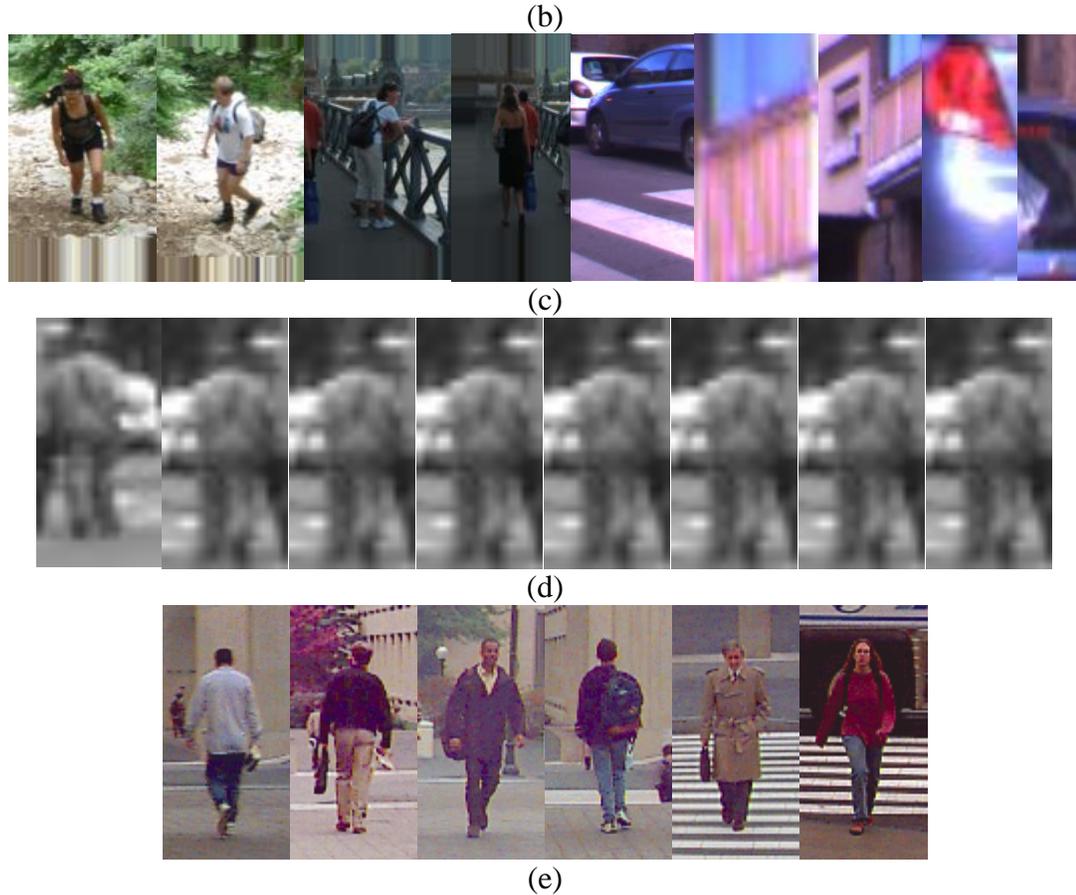


Figura 28 Ejemplos de las bases de datos disponibles: (a) P_T_IH, (b) CV-C, (c) INRIA, (d) Daimler, (e) MIT.

Con esta base de datos se realizó el entrenamiento de los clasificadores Naive-Bayes y Adaboost para los distintos métodos de extracción de características basados en HOG, como son los casos de las implementaciones de Ludwig (Ludwig, Delgado, Goncalves, & Nunes, 2009), Gao y Xu (Xu & Gao, 2010).

5.2. Curva ROC

La curva ROC (Receiver Operating Characteristic), es un gráfico que ilustra la capacidad de diagnóstico de un sistema clasificador binario, ya que su umbral de discriminación varía. La curva ROC se crea trazando la tasa de verdaderos positivos (TP)

frente a la tasa de falsos positivos (TF) en varios umbrales. La tasa de verdadero positivo también se conoce como sensibilidad (MathWorks, 2017). La tasa de falsos positivos también se conoce como caída o probabilidad de falsa alarma (MathWorks, 2017).

A continuación se presenta en la **Figura 29**, **Figura 30**, **Figura 31**, **Figura 32** y **Figura 33** las diferentes evaluaciones de las curvas ROC del clasificador Naive-Bayes + Adaboost con las diferentes bases de datos de evaluación ya mencionadas anteriormente, para el método de extracción de características HOG Ludwig (Ludwig, Delgado, Goncalves, & Nunes, 2009), variando el número de clasificadores débiles.

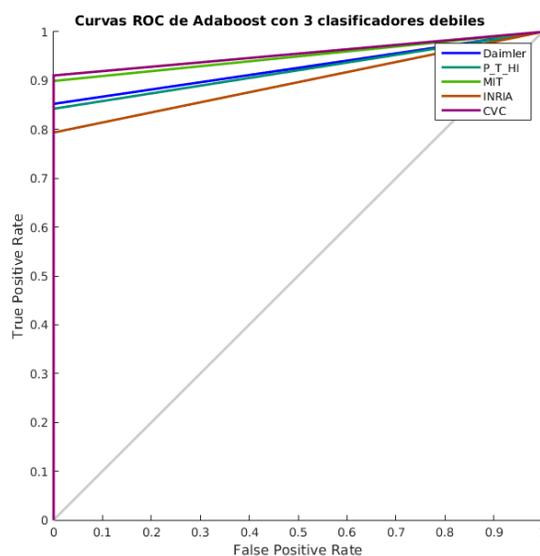


Figura 29 Curva ROC para el clasificador Naive-Bayes + Adaboost con el descriptor HOG con la variación Ludwig con 3 clasificadores débiles.

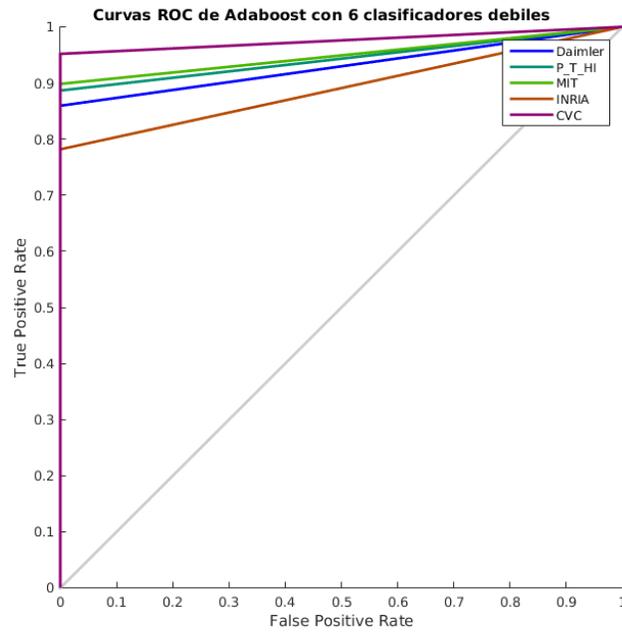


Figura 30 Curva ROC para el clasificador Naive-Bayes + con el descriptor HOG con la variación Ludwig con 6 clasificadores débiles.

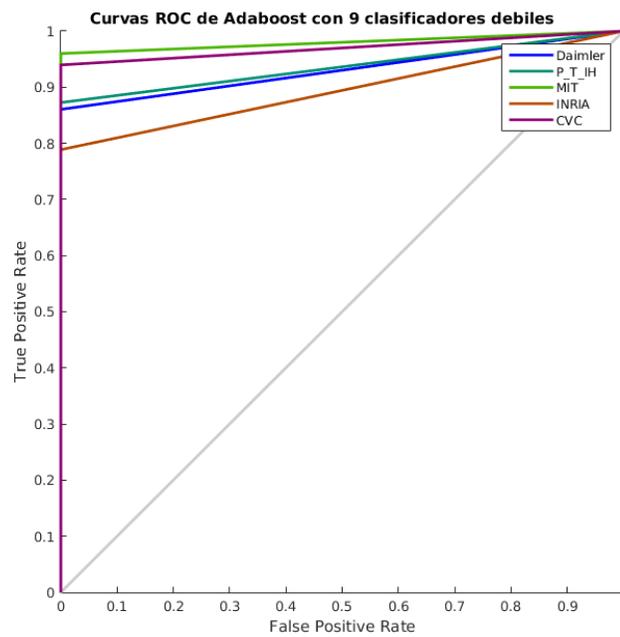


Figura 31 Curva ROC para el clasificador Naive-Bayes + Adaboost con el descriptor HOG con la variación Ludwig con 9 clasificadores débiles.

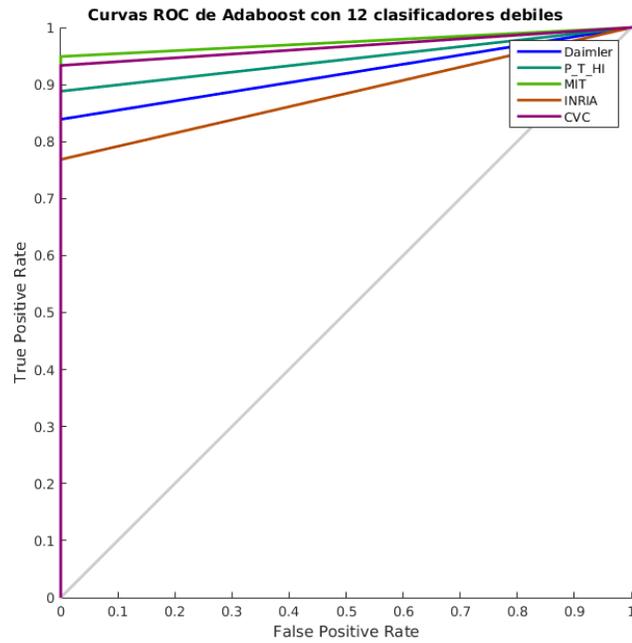


Figura 32 Curva ROC para el clasificador Naive-Bayes + Adaboost con el descriptor HOG con la variación Ludwig con 12 clasificadores débiles.

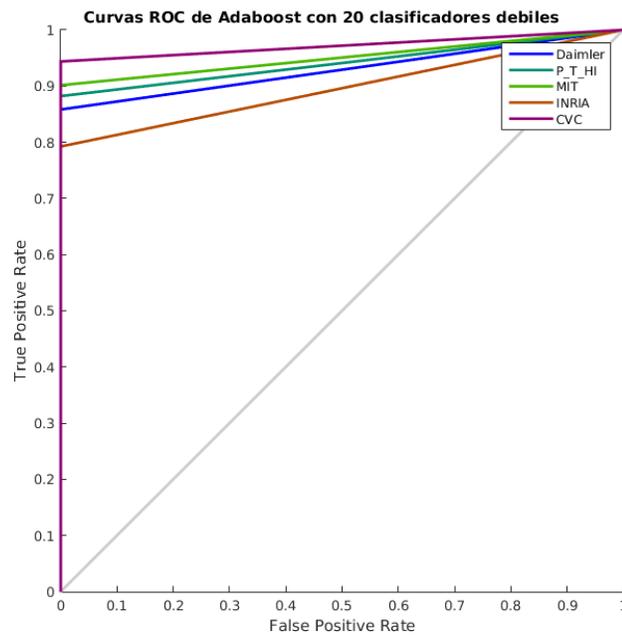


Figura 33 Curva ROC para el clasificador Naive-Bayes + Adaboost con el descriptor HOG con la variación Ludwig con 20 clasificadores débiles.

En las **Figura 34**, **Figura 35**, **Figura 36**, **Figura 37** y **Figura 38** se presenta en las diferentes evaluaciones de las curvas ROC del clasificador Naive-Bayes + Adaboost con las diferentes bases de datos de evaluación ya mencionadas anteriormente, para el método de extracción de características HOG Gao (Xu & Gao, 2010), variando el número de clasificadores débiles.

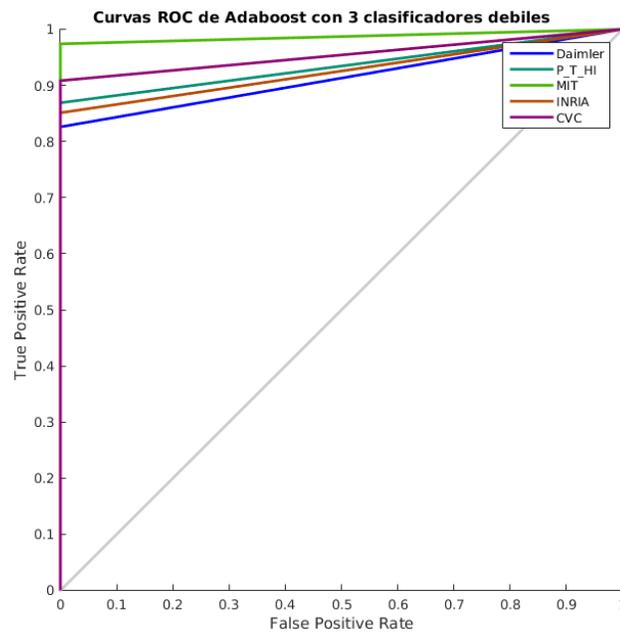


Figura 34 Curva ROC para el clasificador Naive-Bayes + Adaboost con el descriptor HOG con la variación Gao con 3 clasificadores débiles.

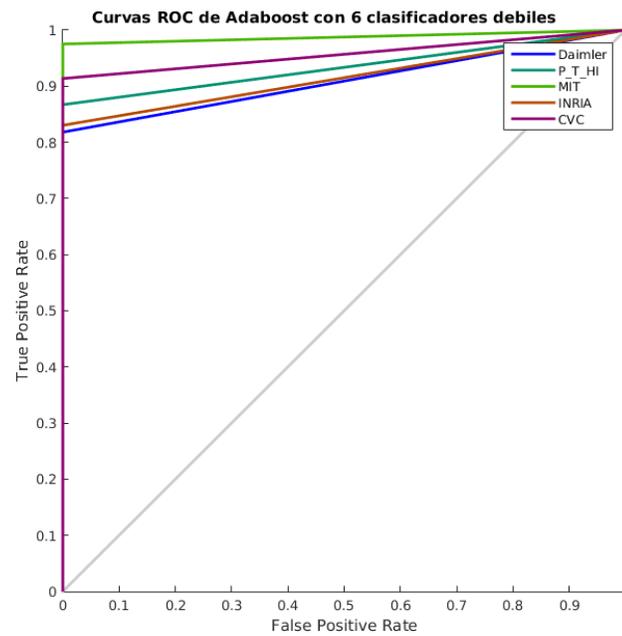


Figura 35 Curva ROC para el clasificador Naive-Bayes + Adaboost con el descriptor HOG con la variación Gao con 6 clasificadores débiles.

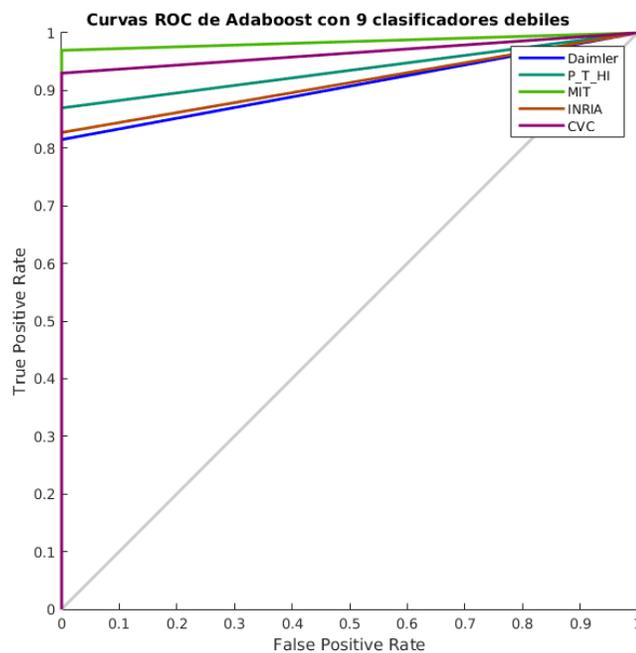


Figura 36 Curva ROC para el clasificador Naive-Bayes + Adaboost con el descriptor HOG con la variación Gao con 9 clasificadores débiles.

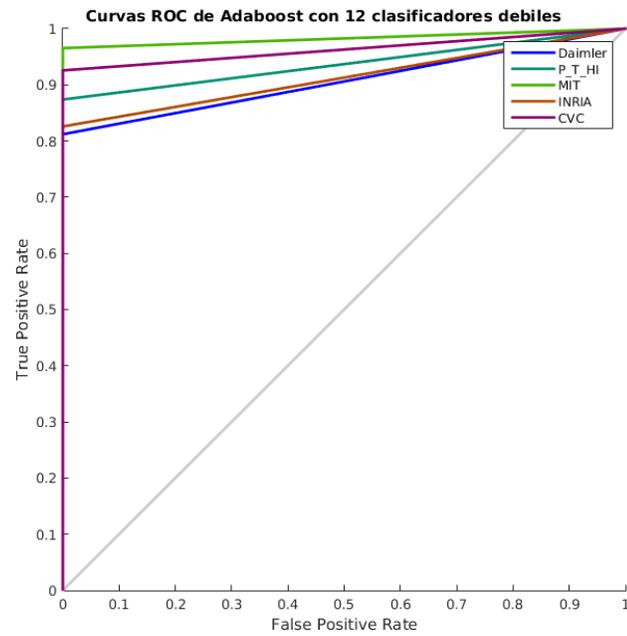


Figura 37 Curva ROC para el clasificador Naive-Bayes + Adaboost con el descriptor HOG con la variación Gao con 12 clasificadores débiles.

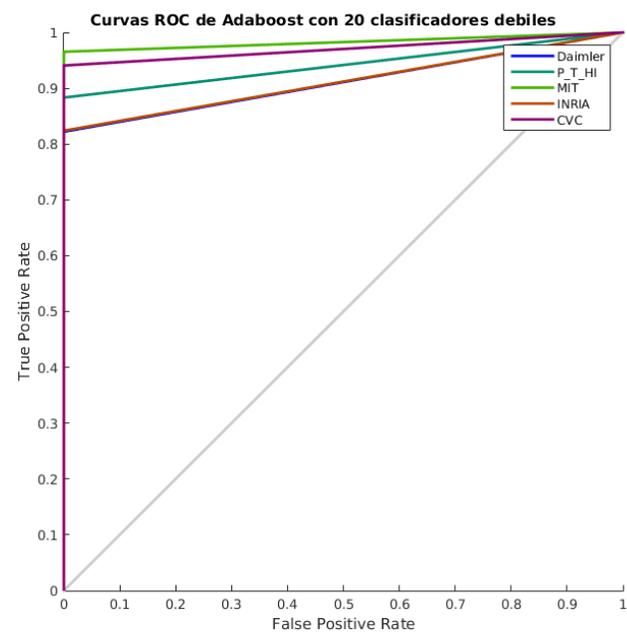


Figura 38 Curva ROC para el clasificador Naive-Bayes + Adaboost con el descriptor HOG con la variación con 20 clasificadores débiles.

5.3. Curvas DET

La curva DET (Detection Error Tradeoff) es un gráfico de tasas de error para sistemas de clasificación binarios, que representa la tasa de falsos negativos frente a la tasa falsos positivos (Martin, Doddington, Kamm, Ordowski, & Przybocki, 2017). Los ejes x, y se escalan de forma no lineal por sus desviaciones normales estándar (o simplemente por transformación logarítmica), produciendo curvas de intercambio que son más lineales que las curvas ROC.

A continuación se presenta en la **Figura 39**, **Figura 40**, **Figura 41**, **Figura 42** y **Figura 43** las diferentes evaluaciones de las curvas DET para el clasificador Naive-Bayes + Adaboost con las diferentes bases de datos de evaluación ya mencionadas anteriormente, para el método de extracción de características HOG Ludwig (Ludwig, Delgado, Goncalves, & Nunes, 2009), variando el número de clasificadores débiles.

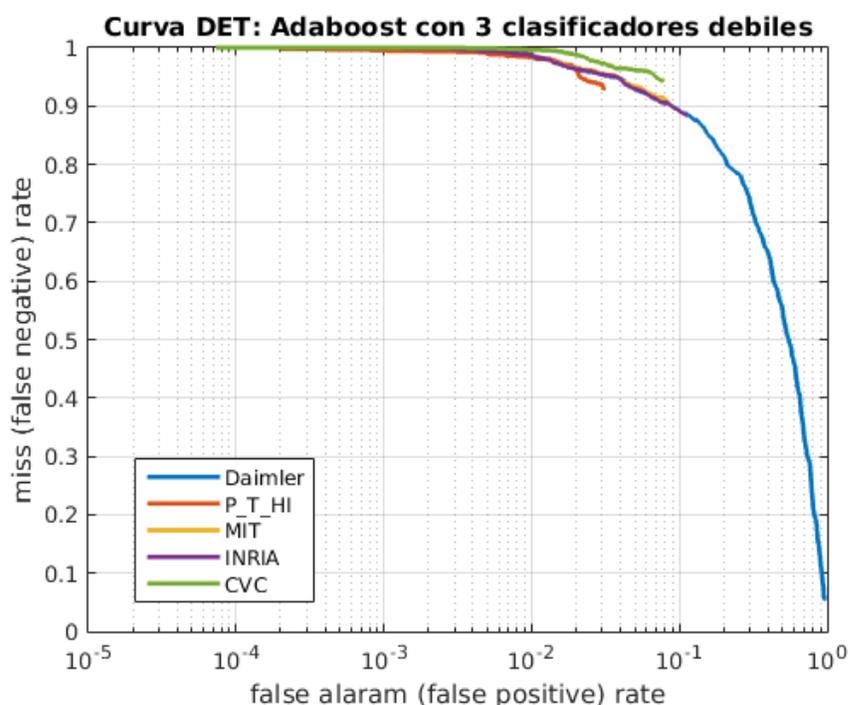


Figura 39 Curva DET para el clasificador Nave-Bayes + Adaboost con el descriptor HOG con la variación Ludwig con 3 clasificadores débiles.

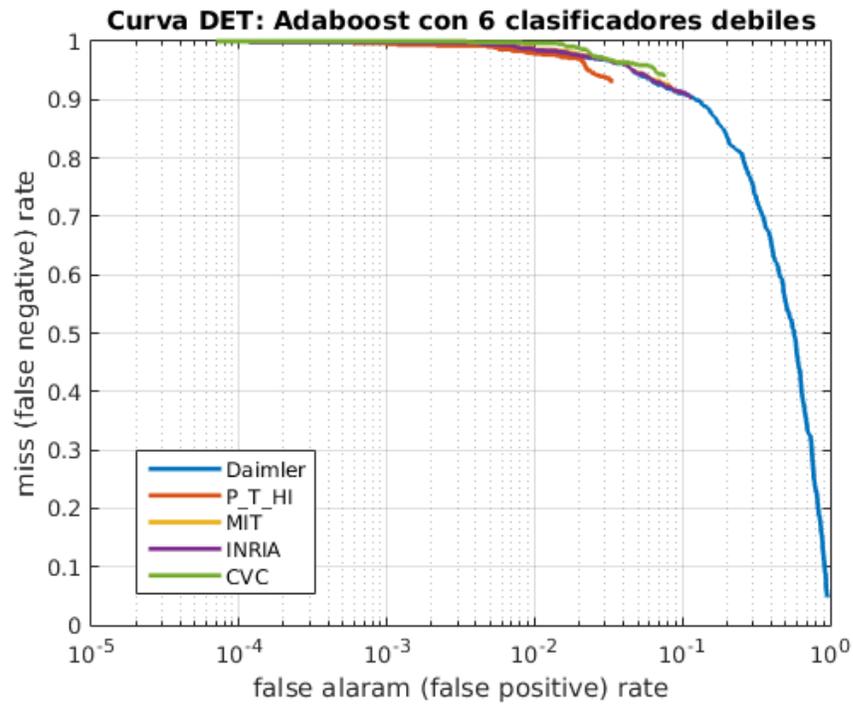


Figura 40 Curva DET para el clasificador Nave-Bayes + Adaboost con el descriptor HOG con la variación Ludwig con 6 clasificadores débiles.

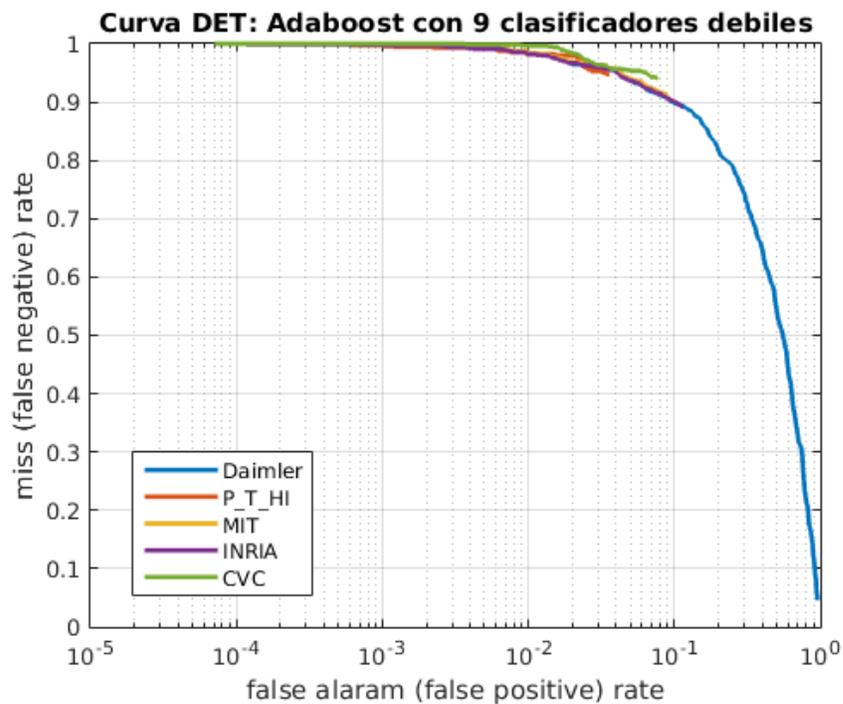


Figura 41 Curva DET para el clasificador Nave-Bayes + con el descriptor HOG con la variación Ludwig con 9 clasificadores débiles.

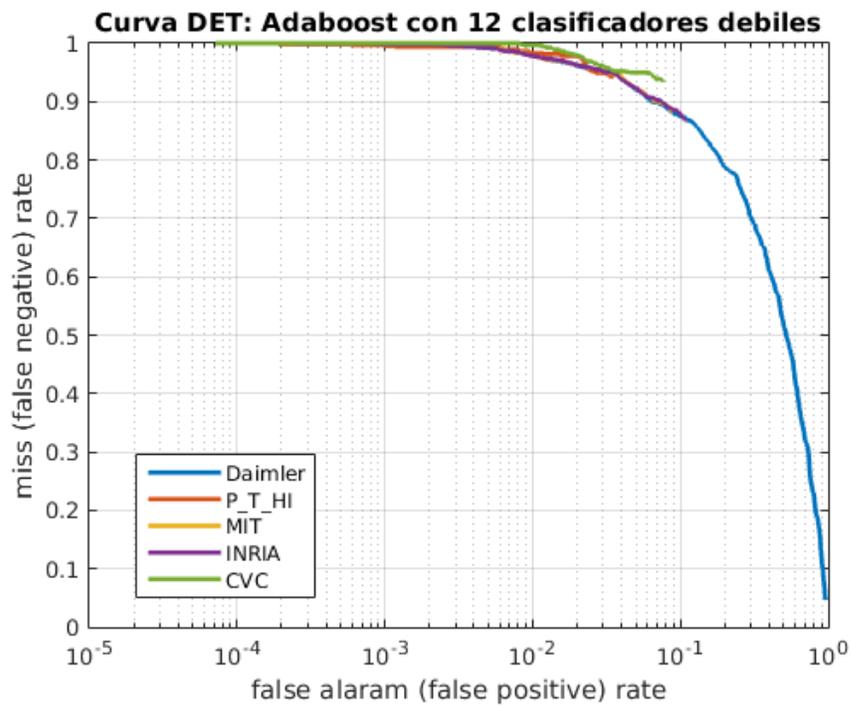


Figura 42 Curva DET para el clasificador Nave-Bayes + Adaboost con el descriptor HOG con la variación Ludwig con 12 clasificadores débiles.

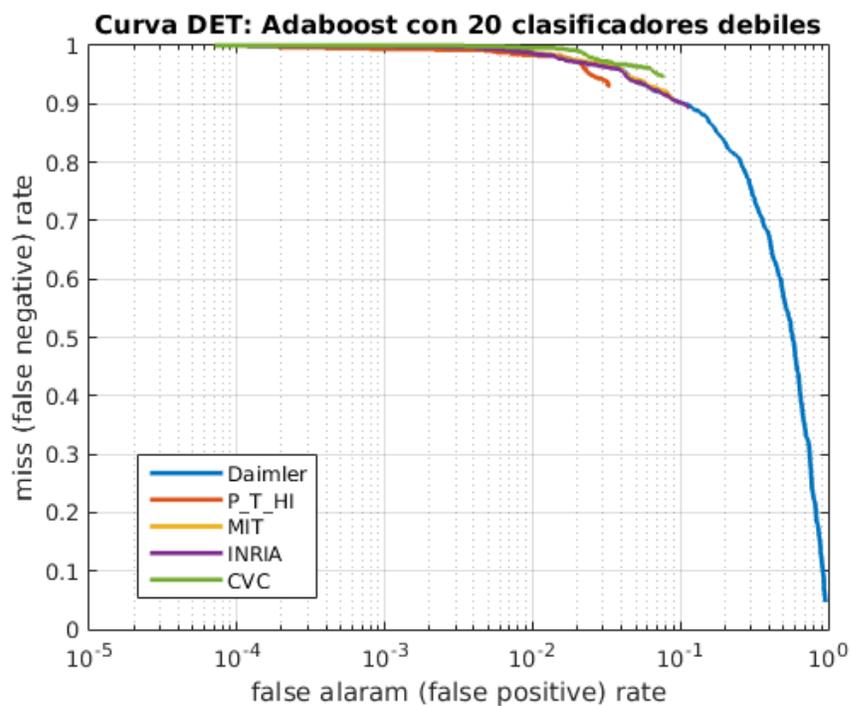


Figura 43 Curva DET para el clasificador Nave-Bayes + Adaboost con el descriptor HOG con la variación Ludwig con 20 clasificadores débiles.

En las **Figura 44**, **Figura 45**, **Figura 46**, **Figura 47** y **Figura 48** se presenta en las diferentes evaluaciones de las curvas DET para el clasificador Naive-Bayes + Adaboost con las diferentes bases de datos de testeo ya mencionadas anteriormente, para el método de extracción de características HOG Gao (Xu & Gao, 2010), variando el número de clasificadores débiles.

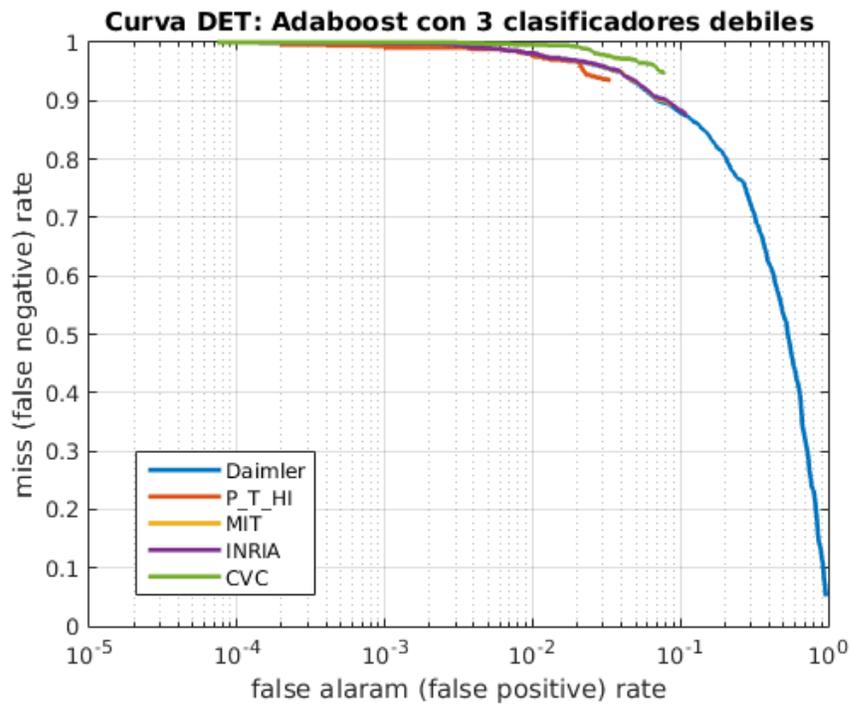


Figura 44 Curva DET para el clasificador Naive-Bayes + Adaboost con el descriptor HOG con la variación Gao con 3 clasificadores débiles.

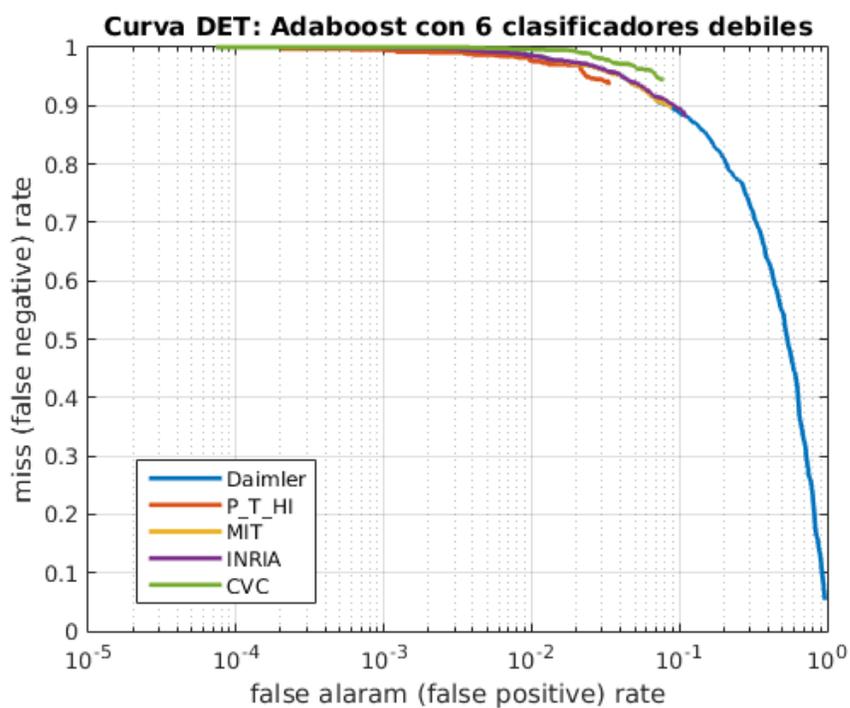


Figura 45 Curva DET para el clasificador Nave-Bayes + Adaboost con el descriptor HOG con la variación Gao con 6 clasificadores débiles.

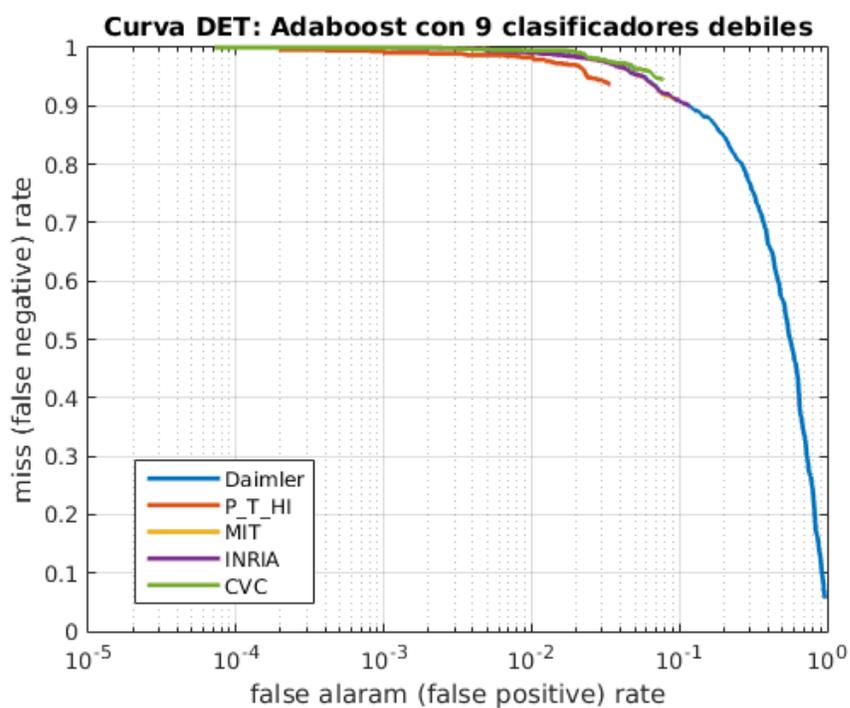


Figura 46 Curva DET para el clasificador Nave-Bayes + Adaboost con el descriptor HOG con la variación Gao con 9 clasificadores débiles.

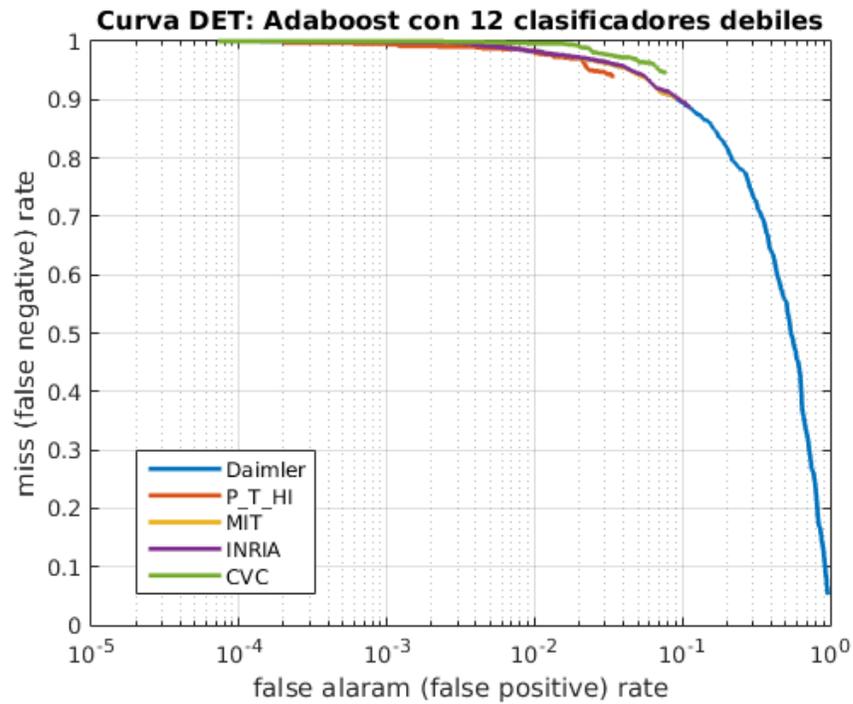


Figura 47 Curva DET para el clasificador Nave-Bayes + Adaboost con el descriptor HOG con la variación Gao con 12 clasificadores débiles.

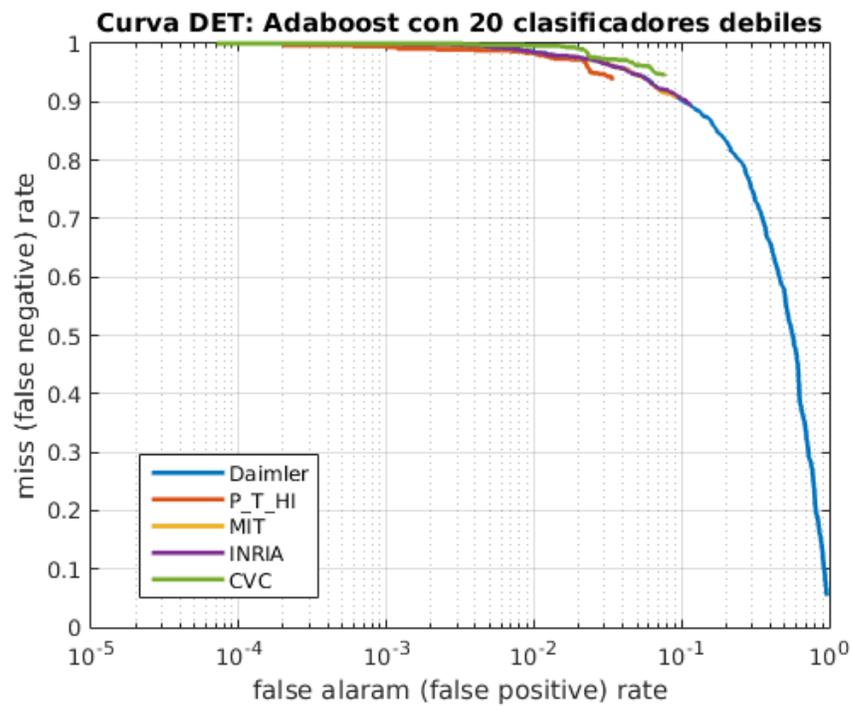


Figura 48 Curva DET para el clasificador Nave-Bayes + Adaboost con el descriptor HOG con la variación Gao con 20 clasificadores débiles.

Observando la **Tabla 3** y **Tabla 6** se determina que el clasificador Naive-Bayes + Adaboost con 9 clasificadores débiles y con el descriptor HOG de Gao, presenta la mayor exactitud (88,23%) y sensibilidad (94,59 %) ante los demás clasificadores, además en la evaluación con las curvas ROC **Figura 36** y DET **Figura 46** muestran un mayor desempeño.

5.4. Resultados Experimentales del Clasificador

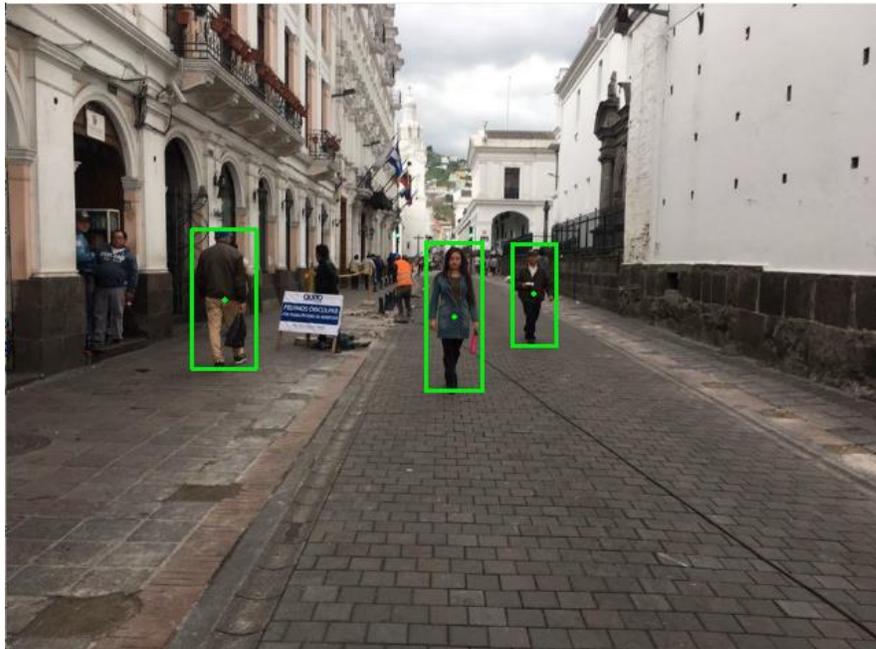
Una vez determinado el clasificador con mayor eficiencia se procedió a realizar pruebas experimentales del generador de ROIs + el clasificador obteniendo resultados óptimos como se muestran en la **Figura 49** y **Figura 50**.



(a)



(b)

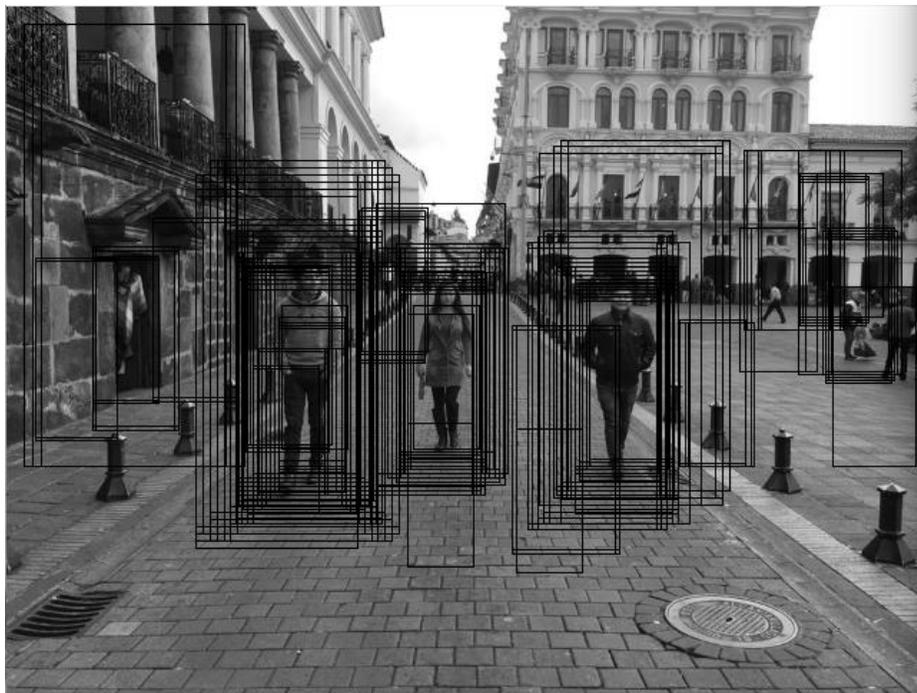


(c)

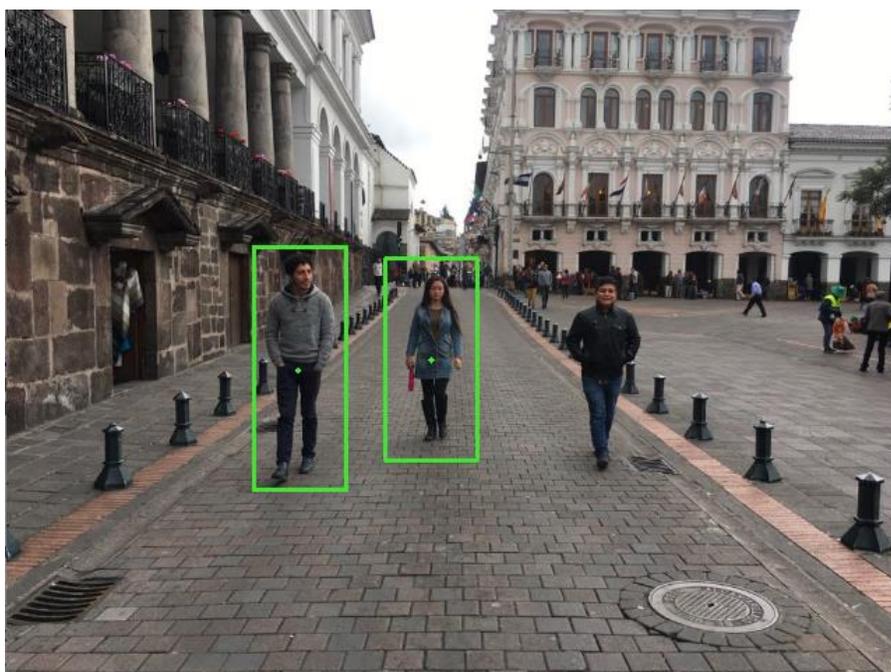
Figura 49 Resultados del Detector donde (a) es el fotograma original, (b) son las ROIs generadas en el fotograma y (c) es el resultado final del en donde se excluyen las ROIs que no contiene un peatón mediante la etapa de clasificación.



(a)



(b)



(c)

Figura 50 Resultados del Detector donde (a) es el fotograma original, (b) son las ROIs generadas en el fotograma y (c) es el resultado final del en donde se excluyen las ROIs que no contiene un peatón mediante la etapa de clasificación.

En la **Figura 49(c)** se puede visualizar que el clasificador da falsos negativos con peatones ocluidos parcialmente, en cambio en la **Figura 50(c)** se visualiza de igual forma falsos negativos por dos motivos: el primero es la distancia de detección y el segundo es el error del clasificador.

5.5. Resultados Experimentales del Filtro de Kalman

Una vez realizadas las pruebas del detector (generador de ROIs + clasificador) se procedió a realizar pruebas experimentales del detector + filtro de Kalman en cinco videos diferentes.

En la **Figura 51** se muestra fotogramas del video 1 con el cual se va a realizar el seguimiento del peatón, con el vehículo estático, como se muestra el peatón se mueve desde la parte izquierda del fotograma hasta la parte derecha del fotograma.



Figura 51 Fotogramas del video 1 el cual se usará para evaluar el seguimiento de un peatón.

Una vez realizado el seguimiento del peaton se muestra en la **Figura 52** un fotograma del video en el que se esta realizando el seguimiento en donde se puede observar con color rojo la trayectoria del peaton.



Figura 52 Fotograma del video ya realizado el seguimiento del peatón.

En la **Figura 53** se tiene una gráfica de la trayectoria del peatón que se encuentra en la **Figura 52** en donde se muestra: la trayectoria real del peatón en color azul, la trayectoria generada por el filtro de Kalman en color rojo y los puntos en donde el peatón fue localizado por el detector en color celeste. Estos datos están graficados respecto a las coordenadas del fotograma que tiene una dimensión de 640x480 pixeles.

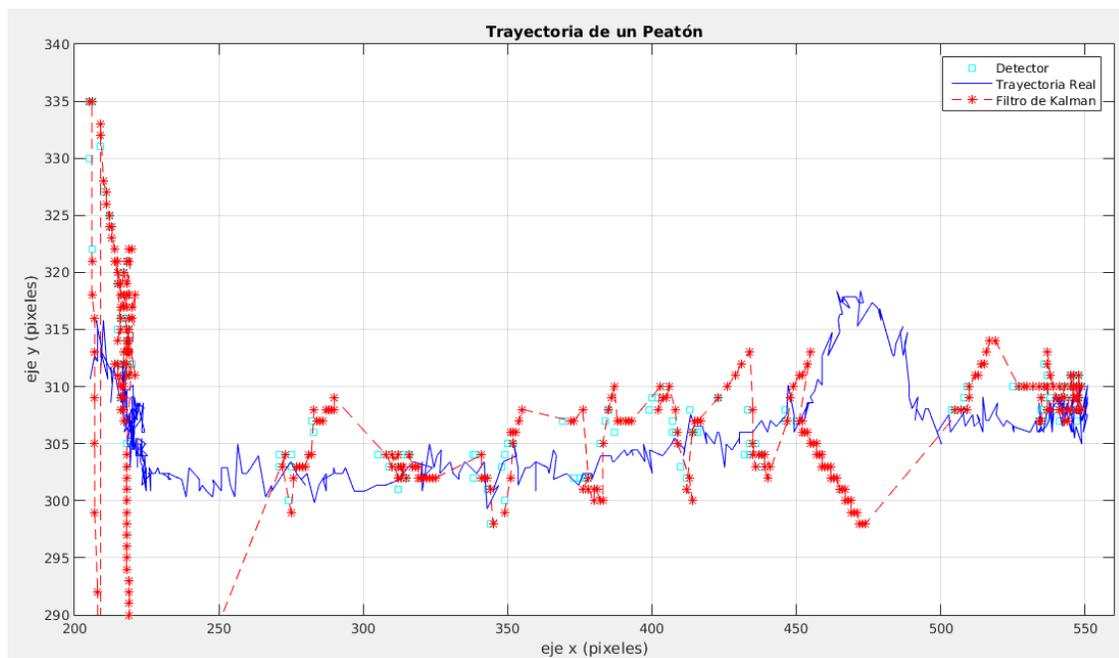


Figura 53 Resultados del seguimiento realizado de peatón del video 1 en una escena sintética con una sola persona.

En la **Figura 54** se muestra fotogramas del video 2 con el cual se va a realizar el seguimiento del peatón y en la **Figura 55** se muestra el resultado del seguimiento realizado.



Figura 54 Fotogramas del video 2 el cual se usará para evaluar el seguimiento de un peatón.

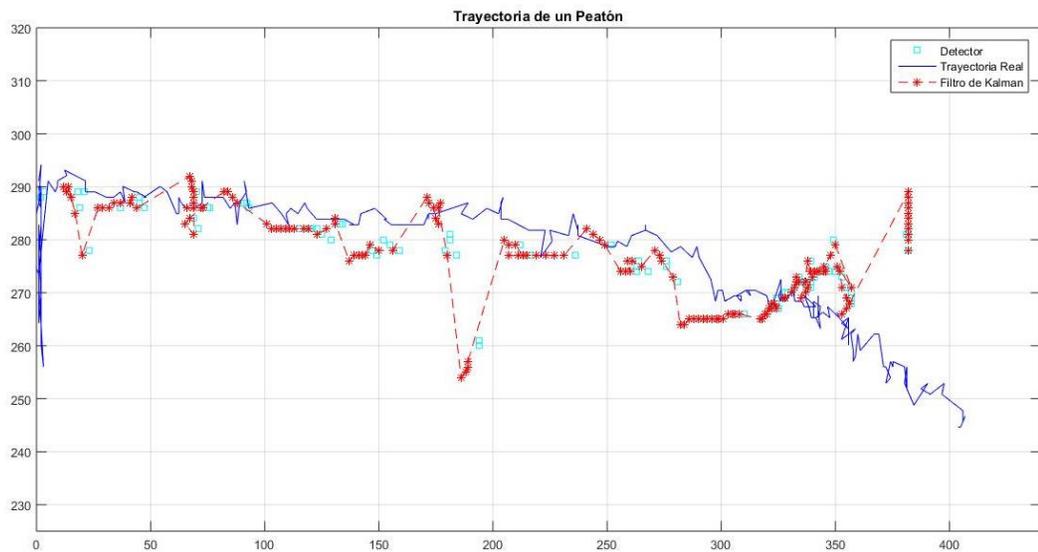


Figura 55 Resultados del seguimiento realizado de peatón del video 2 en una escena sintética con una sola persona.

En la **Figura 56** se muestra fotogramas del video 3 con el cual se va a realizar el seguimiento del peatón y en la **Figura 57** se muestra el resultado del seguimiento realizado.



Figura 56 Fotogramas del video 3 el cual se usará para evaluar el seguimiento de un peatón.

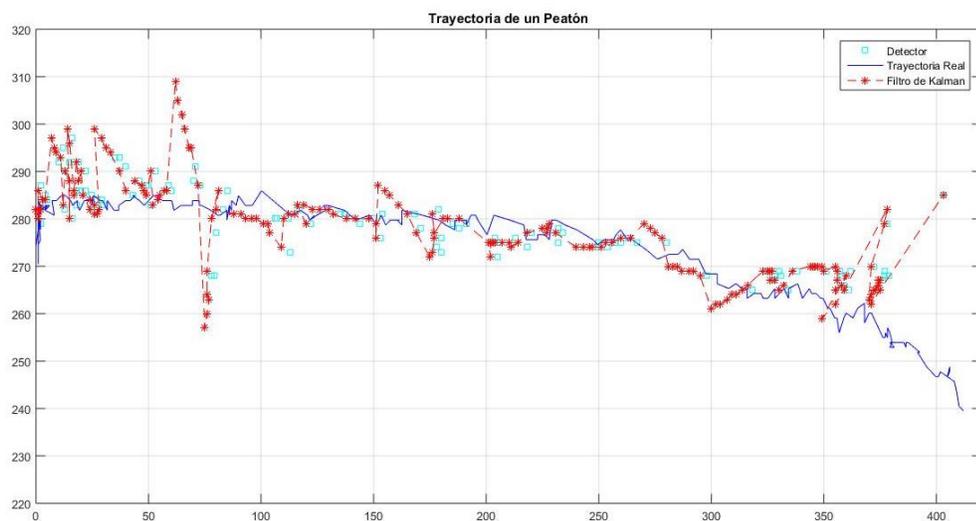


Figura 57 Resultados del seguimiento realizado de peatón del video 3 en una escena sintética con una sola persona.

En la **Figura 58** se muestra fotogramas del video 4 con el cual se va a realizar el seguimiento del peatón y en la **Figura 59** se muestra el resultado del seguimiento realizado.



Figura 58 Fotogramas del video 4 el cual se usará para evaluar el seguimiento de un peatón.

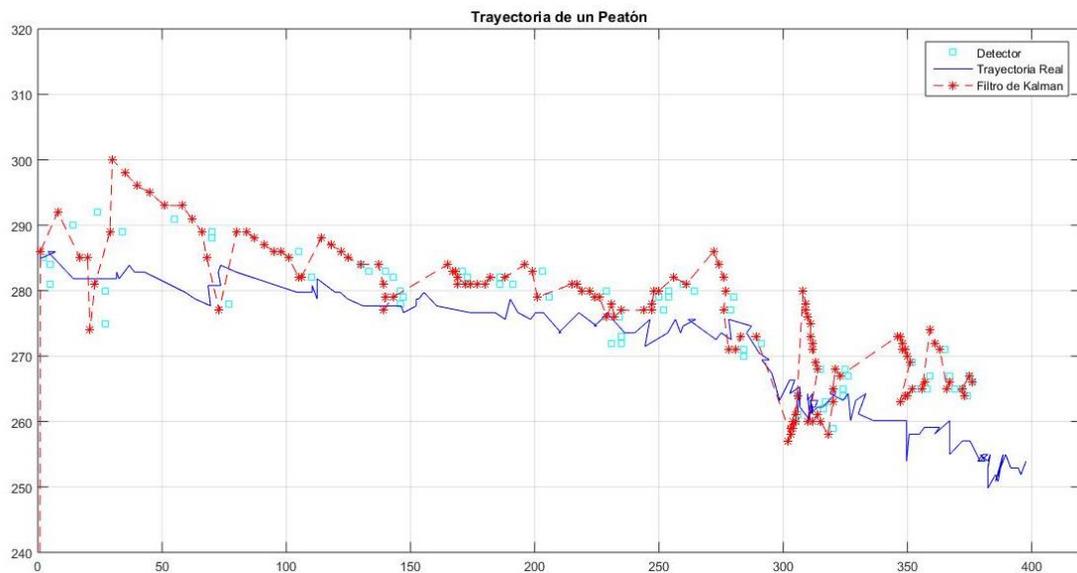


Figura 59 Resultados del seguimiento realizado de peatón del video 4 en una escena sintética con una sola persona.

En la **Figura 60** se muestra fotogramas del video 5 con el cual se va a realizar el seguimiento del peatón y en la **Figura 61** se muestra el resultado del seguimiento realizado.



Figura 60 Fotogramas del video 5 el cual se usara para evaluar el seguimiento de un peatón.

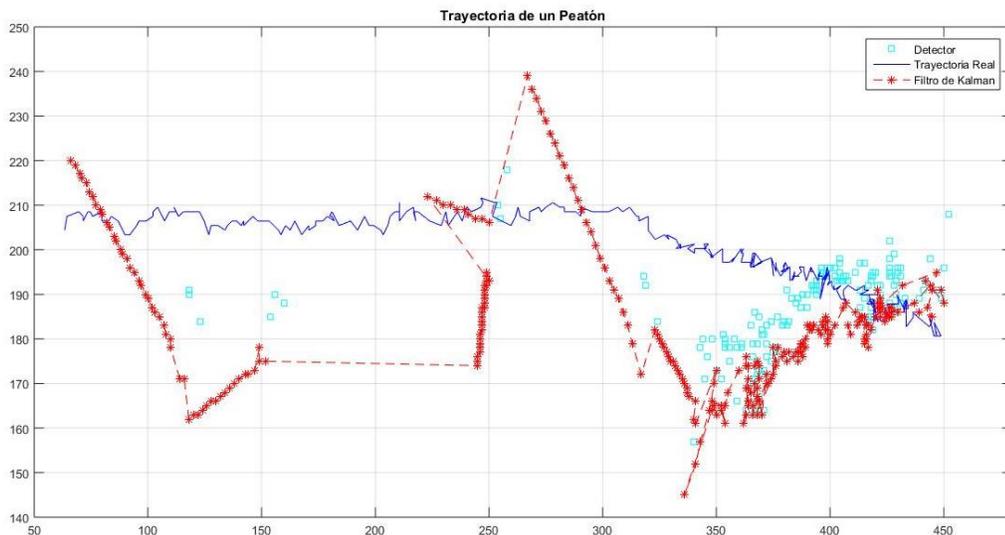


Figura 61 Resultados del seguimiento realizado de peatón del video 5 en una escena sintética con una sola persona.

Evaluando los resultados de la gráfica que se muestra en la **Figura 53**, **Figura 55**, **Figura 57**, **Figura 59** y **Figura 61**, con la utilización del clasificador Naive-Bayes + Adaboost para poder obtener el número de predicciones correctas e incorrectas que realizo el filtro de Kalman se obtuvo los resultados de la **Tabla 10**.

Tabla 10
Resultados de evaluación de trayectoria

Video	Correctas	Incorrectas	Error %
Video 1	807	135	14,00
Video 2	495	75	13,15
Video 3	615	105	14,58
Video 4	428	57	13,01
Video 5	894	114	12,75
Promedio			13,49

Se obtuvo un error promedio del 13,49%, cabe recalcar que el filtro de Kalman realiza la predicción del estado generando una ROI en el tiempo t+1 la misma que es evaluada con el clasificador Naive-Bayes + Adaboost para obtener el error del seguimiento, para que el clasificador nos dé como resultado que efectivamente se encuentra un peatón en la ROI es necesario que el peatón se encuentre completo en la ROI caso contrario si la ROI lo recorta al peatón el clasificador dará como resultado que es una predicción incorrecta ya que su limitación es que el peatón debe visualizarse completamente en la ROI.

En la **Figura 62** se muestra las curvas FPPI de los videos mencionados anteriormente, obteniendo como resultado una tasa de fallas promedio en escala logarítmica MR(%) de 41,02% en el video 1, 34,42% en el video 2, 44,71% para en video 3, 39,86% para el video 4 y 41,77% en el video 5.

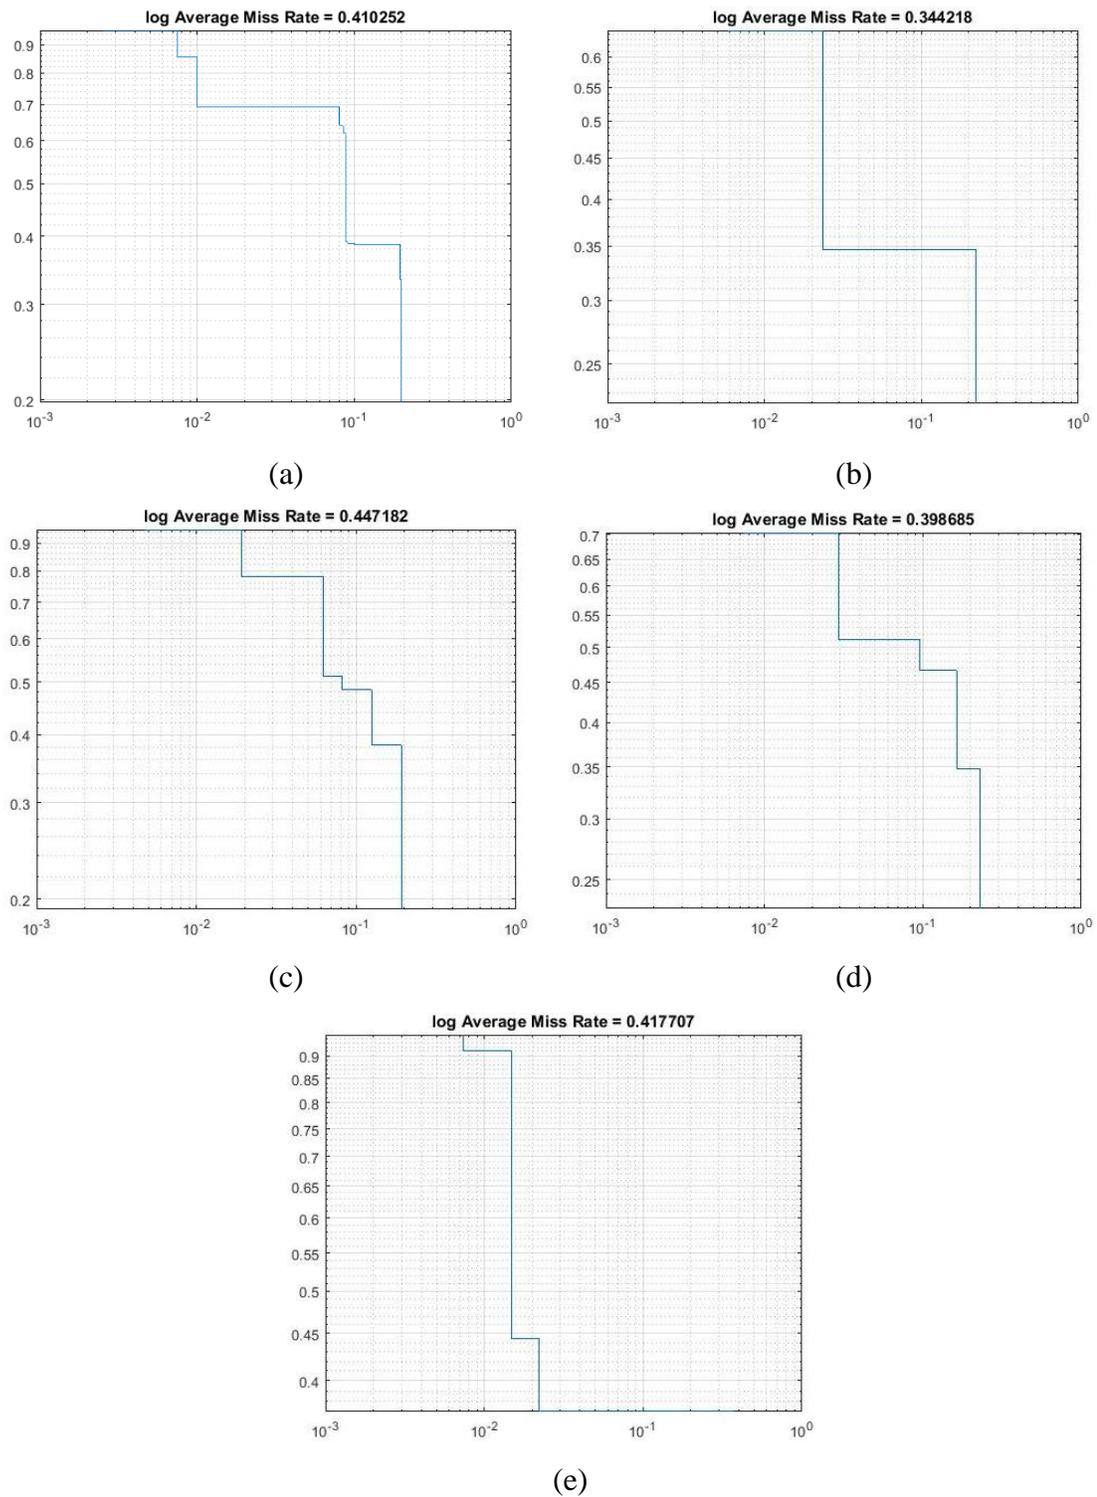


Figura 62 Curvas FPPI del seguimiento del peatón del (a) video 1, (b) video 2, (c) video 3, (d) video 4 y (e) video 5.

Obteniendo una tasa de fallas promedio en escala logarítmica promedio de los dos videos MR(%) de 40,35%, este valor esta alrededor de trabajos de investigación de (Costea & Nedevschi, 2014) y (Yan, Zhang, & Lei, 2013), con un MR(%) de 42.30% y 40.52% respectivamente.

Sin embargo, el rendimiento depende en gran medida de la detección confiable. Si la detección falla ocurre una oclusión prolongada, el rendimiento se deteriora significativamente (Hui & James, 2014).

CAPÍTULO VI

6. CONCLUSIONES Y TRABAJOS FUTUROS

6.1. Conclusiones

En el presente trabajo de investigación se presentó un algoritmo de clasificación y uno de seguimiento de peatones.

Para el entrenamiento y validación del algoritmo de clasificación, se construyó una base de datos global, recolectando imágenes de Daimler (Daimler, 2013), INRIA (INRIA, 2005), P_T_HI (Flores, Robayo, & Saa, 2015), MIT (MIT, s.f.), CVC-03 (Elektra, 2010), las cuales proporcionan imágenes de personas en diferentes posturas, tamaño, forma y con distintas condiciones climáticas, para formar un clasificador robusto.

Primero se realizó el estudio del clasificador débil para cuantificar la probabilidad de encontrar un peatón en el fotograma, este valor se obtuvo empíricamente realizando un experimento en donde se calcula la eficiencia del clasificador para cada valor de la probabilidad de que exista un peatón en el fotograma ($P(C_k)$), que es la probabilidad de que un peatón $P(C_1)$ y no peatón $P(C_2)$ se encuentre en un fotograma. Dando como resultado que este valor afecta notoriamente en la eficiencia del clasificador cuando se utiliza los descriptores HOG Ludwig y Gao siendo el valor óptimo 0,01%, a diferencia de cuando se utiliza el descriptor HOG Xu este valor no produce una variación en la eficiencia del clasificador.

Luego, para el entrenamiento del clasificador fuerte, se presenta un algoritmo que entrena los clasificadores débiles, con diferentes bases de datos las cuales están compuestas de muestras de la base global, la selección de muestras depende del factor de corrección α que se calcula en función del error del clasificador débil entrenado anteriormente. Para la determinación del clasificador con mayor eficiencia, se entrenaron diferentes clasificadores fuertes variando el número de clasificadores débiles en 3, 6,9 y 12, para los métodos de extracción de características basadas en HOG con las

implementaciones de Ludwig, Gao y Xu. Concluyendo que un clasificador fuerte con 9 clasificadores débiles y utilizando el método de extracción de características HOG Gao se destaca entre los demás con una exactitud de 85,2% y sensibilidad de 93,76%, medido sobre la base de datos de validación conformada por 19974 imágenes de peatones y 37274 imágenes de no peatones.

El algoritmo de seguimiento, basado en la localización de peatones reduce la inexactitud de la localización causada por fallas en la clasificación y ruido en la imagen, enfocándose a realizar el seguimiento cuando el detector deje de funcionar por oclusión del peatón o falsos negativos en el clasificador. Finalmente se evaluó el algoritmo completo que incluye (*Generador de ROI + Clasificador*) + *Filtro de Kalman* mediante la generación de las curvas FPPI dando como resultado una tasa de fallas promedio logarítmica de 41,02%, la misma que supera trabajos de investigación del estado del arte como el algoritmo WordChannels (Costea & Nedevschi, 2014).

6.2. Trabajos futuros

El presente trabajo de investigación es un buen punto de partida para el desarrollo de sistemas ADAS, existen varios temas de investigación que sirven como complemento y mejora para el sistema implementado en esta investigación entre los cuales tenemos:

Paralelizar.- En la actualidad existen tarjetas GPU las cuales realizan distintos procesos paralelamente en un mismo instante de tiempo, Además cuentan con su propia memoria RAM, reduce tiempo de ejecución .

Múltiple seguimiento.- Se han desarrollado algoritmos con una gran precisión de asignación de etiquetas, uno de los principales es el algoritmo de Hurgarían que se basa en la asociación de datos pero con deficiencias en el caso de intersecciones de dos o más peatones. Para este caso se propone la investigación de: (Ken & Gyu, 2013) (Imaging & Visualization Department, 2000) la cual utiliza el coeficiente de Bhattacharyya para encontrar la relación entre fragmentos de una ROI y determinar qué datos corresponde a cada target.

Visión Estéreo.- Este sistema permite la simulación de los ojos humanos, utilizando dos cámaras separadas a una distancia d , permitiendo determinar la distancia del peatón a la cámara, además proporcionando un ángulo de visión mayor, que con la utilización de una sola cámara, Por lo tanto permite la posibilidad de realizar un multitracking de peatones en 3D.

REFERENCIAS BIBLIOGRÁFICAS

- Darrell, T., Gordon, G., Harville, M., & Woodfill, J. (june de 2000). Integrated Person Tracking Using Stereo, Color, and Pattern Detection. *International Journal of Computer Vision*, 37, 175-185. Obtenido de <https://link.springer.com/article/10.1023/A:1008103604354>
- Zheng, G., & Chen, Y. (2012). A Review on Vision-Based Pedestrian Detection. *IEEE*.
- Agencia Nacional de Trancito. (2015). *Fallecidos Diciembre 2015*. Obtenido de [http://www.ant.gob.ec/index.php/descargable/file/3367-fallecidos-diciembre-2015%20\[%C3%9Altimo%20acceso:%2019%2010%202016\]](http://www.ant.gob.ec/index.php/descargable/file/3367-fallecidos-diciembre-2015%20[%C3%9Altimo%20acceso:%2019%2010%202016]).
- Agencia Nacional de Trancito. (2016). *Fallecidos Octubre 2016*. Obtenido de <http://www.ant.gob.ec/index.php/descargable/file/3664-fallecidos-mayo-2016>
- Agencia Naconal de Trancito. (2015). *Siniestros Octubre 2015*. Obtenido de [http://www.ant.gob.ec/index.php/descargable/file/3265-%20siniestros-octubre-2015.%20\[%C3%9Altimo%20acceso:%2019%2010%202016\]](http://www.ant.gob.ec/index.php/descargable/file/3265-%20siniestros-octubre-2015.%20[%C3%9Altimo%20acceso:%2019%2010%202016]).
- Armin's Notebook. (15 de April de 2016). Real-time speed estimation of cars with OpenCV. *Armin's Notebook*. Obtenido de <http://www.amphioxus.org/content/real-time-speed-estimation-cars>
- Arndt, R., Schweiger, R., & Ritter, W. (13 de August de 2007). Detection and Tracking of Multiple Pedestrians in Automotive. *IEEE*. doi:10.1109/IVS.2007.4290084
- Bagherpour, P., & Cheraghi, S. (2012). Upper Body Tracking Using KLT and Kalman Filter. *ELSEVIER*. Obtenido de <https://www.sciencedirect.com/science/article/pii/S187705091200734X>
- Bar-Hillel, A., Levi, D., & Krupka, E. (2010). Part-Based Feature Synthesis for Human Detection. *ECCV*.
- Benenson, R., Mathias, M., & Tuytelaars, T. (2013). Seeking the strongest rigid detector. *CVPR*.
- Bernd, M., & Gerald, K. (2003). *IR pedestrian detection for advanced driver assistance systems* (Vol. 2781).
- Bertozzi, M., Broggi, A., & Grisleri, P. (2003). Pedestrian detection in infrared images. *Intelligent Vehicles Symposium, 2003. Proceedings. IEEE*.
- Bertozzi, M., Broggi, A., Fascioli, A., & Tibaldi, A. (2004). Pedestrian localization and tracking system with Kalman filtering. *IEEE*. doi:10.1109/IVS.2004.1336449
- Bradski, G. (2002). Real time face and object tracking as a component of a perceptual user interface. *IEEE*. doi:10.1109/ACV.1998.732882

- Brief introduction to Intelligent Transportation System, ITS.* (s.f.). Recuperado el 15 de Noviembre de 2016, de <https://www.freeway.gov.tw/UserFiles/File/Traffic/A1%20Brief%20introduction%20to%20Intelligent%20Transportation%20System,%20ITS.pdf>
- Broggi, A., Bertozzi, M., & Sechi, M. (Octubre de 2000). Shape-based pedestrian detection,. *Intelligent Vehicles Symposium, 2000. IV 2000. Proceedings of the IEEE*, 215-220. doi:10.1109/IVS.2000.898344
- Cai, Q., & Aggarwal, J. (Noviembre de 1999). Tracking human motion in structured envi-. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 21, 1241-1247. doi:10.1109/34.809119
- CAN. (20 de Diciembre de 2016). *Accidentes de tránsito en la Comunidad Andina, 2006-2015.* Obtenido de <http://intranet.comunidadandina.org/Documentos/DEstadisticos/SGDE754.pdf>
- Castañeda Cárdenas, J. A., Nieto Arias, M. A., & Ortiz Bravo, V. A. (2013). Análisis y Aplicación del filtro de Kalman a una señal con ruido aleatorio. *Universidad Tecnológica de Pereira.*
- CEA. (s.f.). *El Sistema ADAS ayuda a prevenir accidentes de tráfico.* Obtenido de <https://www.seguridad-vial.net/vehiculo/seguridad-pasiva/156-el-sistema-adas-ayuda-a-prevenir-accidentes-de-trafico-a-los-conductores>
- Cepal. (2012). *Sistemas inteligentes de transporte en la logística portuaria latinoamericana.*
- CEPAL. (2015). *América Latina y el Caribe mantienen una alta tasa de mortalidad por siniestros de tránsito.*
- Chen, G., Ding, Y., & Xiao, J. (2013). Detection Evolution with Multi-Order Contextual Co-occurrence. *CVPR.*
- Collins, R., Lipton, A., & Kanade, T. (2000). A System for Video Surveillance and Monitoring. *DARPA.* Obtenido de https://www.researchgate.net/profile/Takeo_Kanade/publication/2614446_A_System_for_Video_Surveillance_and_Monitoring/links/57e38c0e08ae0e3158a7a826.pdf
- Comaniciu, D., Ramesh, V., & Meer, P. (2002). Real-time tracking of non-rigid objects using mean shift. *IEEE.* doi:10.1109/CVPR.2000.854761
- Comaniciu, D., & Ramesh, V. (2002). Mean shift and optimal prediction for efficient object tracking. *IEEE.*
- Costea, A., & Nedeveschi, S. (2014). Word Channel Based Multiscale Pedestrian Detection Without Image Resizing and Using Only One Classifier. *CVPR.*

- Daimler. (2013). *Daimler Pedestrian Segmentation Benchmark Dataset*. Obtenido de http://www.gavrila.net/Datasets/Daimler_Pedestrian_Benchmark_D/daimler_pedestrian_benchmark_d.html
- Dalal, N., & Triggs, B. (2005). Histograms of oriented gradients for human detection. *CVPR*.
- Deusto. (30 de marzo de 2017). *Vehículos Autónomos y visión artificial*. Obtenido de <https://blogs.deusto.es/aplicaciones-tic/vehiculos-autonomos-y-vision-artificial/#comments>
- Dollár, P., & Appel, R. (2014). Fast Feature Pyramids for Object Detection. *PAMI*.
- Dollár, P., Appel, R., & Kienzle, W. (2012). Crosstalk Cascades for Frame-Rate Pedestrian Detection. *ECCV*.
- Dollár, P., Belongie, S., & Perona, P. (2010). The fastest pedestrian detector in the west. *BMVC*.
- Dollar, P., Tu, Z., & Tao, H. (2007). Feature Mining for Image Classification. *CVPR*.
- Dollár, P., Tu, Z., & Perona, P. (2009). Integral channel features. *BMVC*.
- El Blog Salmón. (2016). *Crecimiento demográfico y económico: una relación no tan clara*. Obtenido de <https://www.elblogsalmon.com/economia/crecimiento-demografico-y-economico-una-relacion-no-tan-clara>
- Elektra. (2010). *CVC-03: Virtual-World Pedestrian Dataset*. Obtenido de <http://adas.cvc.uab.es/elektra/enigma-portfolio/cvc-03-virtual-world-pedestrian-dataset/>
- Elzeni, H., Lakshmanan, S., & Watta, P. (2003). A motion and shape-based pedestrian detection algorithm. *Intelligent Vehicles Symposium, 2003. Proceedings. IEEE*. doi:10.1109/IVS.2003.1212962
- Faragher, R. (September de 2012). *Understanding the Basis of the Kalman Filter Via a Simple and Intuitive Derivation*. Obtenido de <https://courses.engr.illinois.edu/ece420/sp2017/UnderstandingKalmanFilter.pdf>
- Fascioli, A., Broggi, A., & Bertozzi, M. (2004). Pedestrian Localization and Tracking System with Kalman. *IEEE*. doi:10.1109/IVS.2004.1336449
- Fei, L., Yun, Q., Jun, T., & Hua, J. (2014). Moving Target Detection and Active Tracking with a Multicamera Network. *Hindawi Publishing Corporation*.
- Felzenszwalb, P., McAllester, D., & Ramanan, D. (2008). A Discriminatively Trained, Multiscale, Deformable Part Model. *CVPR*.
- Femmi, N., Petrone, G., & Spagnuolo, G. (s.f.). Optimization of perturb and observe maximum power point tracking method. *IEEE*.

- Fickenscher, J., Reinhart, S., Hannig, F., & Teich, J. (2017). Convoy Tracking for ADAS on Embedded GPUs. *IEEE*.
- Flores, M. J., Robayo, D. J., & Saa, D. A. (2015). Histograma del gradiente con múltiples orientaciones (hog-mo) detección de personas. *vinculos*.
- Foytik, J., Sankaran, P., & Asari, V. (2011). Tracking and Recognizing Multiple Faces Using Kalman Filter and ModularPCA. *ELSEVIER*, 1. Obtenido de <https://ai2-s2-pdfs.s3.amazonaws.com/eb6b/8359909749e52eff9b78b037a88468101fd.pdf>
- Freund, Y., & Schapire, R. (September de 1999). A short introduction to boosting. *Artificial Intelligence*.
- Garcia, F., Urdiales, J., Carmona, J., & Martin, D. (2016). Mobile based Pedestrian Detection with Accurate Tracking. *IEEE*.
- Gavrila, D., & Giebel, J. (2002). Shape-based pedestrian detection and. *Intelligent Vehicle Symposium, 2002. IEEE*. doi:10.1109/IVS.2002.1187920
- Gavrila, D., & Munder, S. (July de 2006). Multi-Cue Pedestrian Detection and Tracking from a Moving Vehicle. *International Journal of Computer Vision*, 73. Obtenido de <https://link.springer.com/article/10.1007%2Fs11263-006-9038-7?LI=true>
- Houenou, A., Bonnifait, P., & Cherfaoui, V. (2012). A Track-To-Track Association Method for Automotive Perception Systems. *IEE*.
- Hsu, G., Nguyen, H., & Wu, C. (2013). Pedestrian tracking in low contrast regions using aggregated background model and Silhouette Components. *IEEE*. Obtenido de <http://ieeexplore.ieee.org/document/6460963/>
- Hui, K., & James, G. (2014). Driving Recorder Based On-Road Pedestrian Tracking Using Visual SLAM and Constrained Multiple-Kernel. *IEEE*. doi:10.1109/ITSC.2014.6958111
- Huo, D., Liu, H., & Shang, Z. (2016). Research for pedestrian detection classifier. *IEEE*.
- Imaging & Visualization Department. (2000). Real-Time Tracking of Non-Rigid Objects Means Shift. *IEEE*.
- Indice de accidentes de tránsito en america latina*. (15 de Mayo de 2015). Obtenido de https://prezi.com/lz_pll4-eojf/indice-de-accidentes-de-transito-en-america-latina/
- INRIA. (2005). *INRIA Person Dataset*. Obtenido de <http://pascal.inrialpes.fr/data/human/>
- Julier, S. J., & Uhlmann, J. K. (s.f.). A new extension of the Kalman filter to nonlinear systems. *The University of Oxford*.
- Kaur, R., & Singh, S. (2014). Background modelling, detection and tracking of human in video surveillance system. *Computational Intelligence on Power, Energy and Controls with their impact on Humanity (CIPECH)*. doi:10.1109/CIPECH.2014.7019097

- Ken, C., & Gyu, C. (June de 2013). MULTI-TARGET VISUAL TRACKING AND OCCLUSION DETECTION BY COMBINING BHATTACHARYYA COEFFICIENT AND KALMAN FILTER INNOVATION. *JOURNAL OF ELECTRONICS (CHINA)*, 30.
- Kim, I., Muhammad, M., Wahab, T., & Soh, Y. (2014). Multi-Target Tracking Using Color Information. *International Journal of Computer and Communication Engineering*.
- Korada, N., Pavan, S., & Deekshitulu, Y. (Mayo de 2012). Implementation of Naive Bayesian Classifier and Ada-Boost Algorithm Using Maize Expert System. *International Journal of Information Sciences and Techniques (IJIST)*, 2. Obtenido de <https://pdfs.semanticscholar.org/378a/13c7c46393f7c527580a5d9bcbf9dd11f6e4.pdf>
- Kumar, N., Pavan, S., & Deekshitulu, Y. (May de 2012). Implementation of Naive Bayesian Classifier and Ada_Boost Algorithm Using Maize Expert System. *International Journal of Information Sciences and Techniques*, 2.
- Landázuri, & Desgado. (2015). Diseño y construcción de una plataforma inteligente y portátil para un sistema de visión estéreo para aplicación de visión por computadora en vehículos.
- Levi, D., Silberstein, S., & Bar-Hillel, A. (2013). Fast multiple-part based object detection. *CVPR*.
- Li, C., Guo, L., & Hu, Y. (2010). A new method Combining HOG and Kalman filter for video_based human detection and tracking. *International Congress and Signal Processing*.
- Li, H., Sun, F., Liu, L., & Wang, L. (2 de December de 2015). A novel traffic sign detection method via color segmentation and robust shape matching. *Neurocomputing*, 77-88.
- Lin, Z., & Davis, L. (2008). A Pose-Invariant Descriptor for Human. *ECCV*.
- Liu, X., & Lopes, L. (2004). An improved perturbation and observation maximum power point tracking algorithm for PV arrays. *IEEE*. doi:10.1109/PESC.2004.1355425
- Los accidentes de tránsito son un problema socioeconómico.* (s.f.). Recuperado el 12 de Noviembre de 2016, de http://sanpedrodelapaz.cl/wp-content/uploads/2013/10/accidentes_transito.pdf
- Ludwig, O., Delgado, D., Goncalves, V., & Nunes, U. (2009). Trainable Classifier-Fusion Schemes: An Application To Pedestrian Detection. *IEEE*.
- Lui, M., He, Y., Wei, Y., & Xiang, P. (2017). Plant cell tracking using Kalman filter based local graph matching. *ELSEVIER*, 60. Obtenido de <http://www.sciencedirect.com/science/article/pii/S0262885616301299>
- Luo, P., Tian, Y., & Wang, X. (2014). Switchable Deep Network for Pedestrian Detection. *CVPR*.
- Maji, S., Berg, A., & Malik, J. (2008). Classification using intersection kernel support vector. *CVPR*.

- Mammeri, A., Boukerche, A., & Almulla, M. (6 de December de 2013). Desing of traffic sign detection, recognition, and transmission systems for smart vehicles. (IEEE, Ed.) *IEEE Wireless Communications*, 20, 36-43. doi:10.1109/MWC.2013.6704472
- MAPFRE. (s.f.). *Si todos los coches contaran con tecnología ADAS, se evitarían 50.000 accidentes al año*. Obtenido de <https://www.seguridadvialenlaempresa.com/seguridad-empresas/actualidad/noticias/coches-con-tecnologia-adas-evitarian-50-mil-accidentes.jsp>
- Marcinkowski, P., Korzeniewski, A., & Czyzewski, A. (2011). Human Tracking in Multi-camera Visual Surveillance System. *International Conference on Multimedia Communications, Services and Security*.
- Marín, J., Vázquez, D., & López, A. (2013). Random Forests of Local Experts for Pedestrian Detection. *ICCV*.
- Martin, A., Doddington, G., Kamm, T., Ordowski, M., & Przybocki, M. (2017). *The DET Curve in Assessment of Detection Task Performance*. Obtenido de <http://www.dtic.mil/docs/citations/ADA530509>
- Mathias, M., Benenson, R., & Timofte, R. (2013). Handling Occlusions with Franken-classifiers. *ICCV*.
- MathWorks. (11 de Diciembre de 2017). *Detector Performance Analysis Using ROC Curves*. Obtenido de <https://www.mathworks.com/help/phased/examples/detector-performance-analysis-using-roc-curves.html>
- Merven, B., Nicolls, F., & de Jager, G. (s.f.). Multi-Camera person tracking using an extended Kalman Filter. *Rondebosch*.
- MIT. (s.f.). *Pedestrian MIT*. Obtenido de <http://cbcl.mit.edu/software-datasets/PedestrianData.html>
- Moham A, Papageorgiou, C., & Poggio, T. (2001). "Example-based object detection in images. *IEEE Transactions on Pattern Analysis and Machine Intelligence* (Volume: 23, Issue: 4, Apr 2001).
- Nam, W., Han, B., & Han, J. (2011). Improving object localization using macrofeature layout selection. *ICCV*.
- Nanda, H., & Davis, L. (2002). Probabilistic template based pedestrian detection. *Intelligent Vehicle Symposium, 2002. IEEE*. doi:10.1109/IVS.2002.1187921
- Olmeda, D. (5-7 de Septiembre de 2012). Detección de peatones para sistemas de asistencia a la conducción. *XXXIII Jornadas de Automática*, 985-990. Obtenido de <http://e-archivo.uc3m.es>

- OMS. (2017). *Lesiones causadas por el tránsito*. Obtenido de <http://www.who.int/mediacentre/factsheets/fs358/es/>
- Oren, M., Papageorgiou, C., & Sinha, P. (June de 1997). Pedestrian detection using wavelet templates,. *Computer Vision and Pattern Recognition, 1997. Proceedings., 1997 IEEE Computer Society Conference on*. doi:10.1109/CVPR.1997.609319
- Organización Mundial de la Salud. (s.f.). *Prevención de la violencia y los traumatismos*. Recuperado el 5 de Abril de 2016, de Accidentes de tránsito: http://www.who.int/violence_injury_prevention/road_traffic/es/
- Ouyang, W., & Wang, X. (2012). A Discriminative Deep Model for Pedestrian Detection with Occlusion Handling. *CVPR*.
- Ouyang, W., & Wang, X. (2013). Joint deep learning for pedestrian detection. *ICCV*.
- Ouyang, W., & Wang, X. (2013). Single-Pedestrian Detection aided by Multi-pedestrian Detection. *CVPR*.
- Ouyang, W., Zeng, X., & Wang, X. (2013). Modeling Mutual Visibility Relationship in Pedestrian Detection. *CVPR*.
- Owczarek, M., Baranski, P., & Strumillo, P. (2015). Pedestrian tracking in video sequences: a particle filtering approach. *IEEE*. doi:10.15439/2015F158
- Paisitkriangkrai, S., & Shen, C. (2013). Efficient Pedestrian Detection by Directly Optimizing the Partial Area under the ROC Curve. *ICCV*.
- Papageorgiou, C., & Poggio, T. (1999). A trainable pedestrian detection system. *Image Processing, 1999. ICIP 99. Proceedings. 1999 International Conference on*.
- Park, D., Ramanan, D., & Fowlkes, C. (2010). Multiresolution models for object detection. *ECCV*.
- Philomin, V., Duraaiswami, R., & Davis, L. (2002). Pedestrian tracking from a moving vehicle. *Intelligent Vehicles Symposium, 2000. IV 2000. Proceedings of the IEEE*. doi:10.1109/IVS.2000.898368
- Polana, R., & Nelson, R. (1994). Low level recognition of human motion (or how to get your man without finding his body parts). *Motion of Non-Rigid and Articulated Objects, 1994., Proceedings of the 1994 IEEE Workshop on*. doi:10.1109/MNRAO.1994.346251
- Pranali, K., & Khule, R. (2016). Object Detection and Tracking of Pedestrian for ADAS. *ISSN*. Obtenido de <http://www.ijmetmr.com/oljune2016/KaichePranaliR-ProfKhuleRS-15.pdf>
- Quintana, P., & Acurio, H. (24 de noviembre de 2016). Sistemas Inteligentes de transporte. *el telégrafo*.

- Ramírez, Á. S. (Julio de 2003). *El Filtro de Kalman*. Obtenido de http://www.bccr.fi.cr/investigacioneseconomicas/metodoscuantitativos/Filtro_de_Kalman.pdf
- Real Academia Española. (s.f.). *Diccionario de la lengua española*. Recuperado el 10 de Marzo de 2016, de Edición del Tricentenario: www.rae.es
- Ricquebourg, Y., & Bouthemy, P. (Agosto de 2000). Real-time tracking of moving persons by exploiting spatio-temporal image slices. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22, 797-808. doi:10.1109/34.868682
- Rohr, K. (1993). Incremental recognition of pedestrian from image sequences. *Computer Vision and Pattern Recognition, 1993. Proceedings CVPR '93., 1993 IEEE Computer Society Conference on*, 8-13. doi:10.1109/CVPR.1993.341008
- Rosenhahn, B., Kersting, U., He, L., & Smth, A. (2005). A Silhouette Based Human Motion Tracking System. *Communication and Information Technology*.
- Sabzmeydani, P., & Mori, G. (2007). Detecting pedestrians by learning shapelet features. *CVPR*.
- Safelita. (2016). *Las características de los ADAS, asistencia al conductor*. Obtenido de <https://espanol.safelite.com/windshield-auto-glass-technology/adas>
- Sankaran, P., Asar, V., & Foytik, J. (2011). Tracking and Recognizing Multiple Faces Using Kalman Filter and ModularPCA. *ELSEVIER*. Obtenido de <http://www.sciencedirect.com/science/article/pii/S1877050911005126#>
- Santosh, H., & Mohan, K. (2014). Multiple Objects Tracking Using Extended Kalman Filter, GMM and Mean Shift Algorithm – A comparative Study. *IEEE*.
- Sashua, A., Gdalyahu, Y., & Hayun, G. (8 de Octubre de 2004). Pedestrian detection for driving assistance systems, single frame classification and system level performance. *IEEE*. doi:10.1109/IVS.2004.1336346
- Schwartz, W., Kembhavi, A., & Harwood, D. (2009). Human detection using partial least squares analysis. *ICCV*.
- Seguí, J. M., & Martínez, M. R. (2004). Los Sistemas inteligentes de transporte y sus efectos en la movilidad urbana e interurbana. *Scripta Nova*.
- Sermanet, P., Kavukcuoglu, K., & Chintala, S. (2013). Pedestrian Detection with. *CVPR*.
- Sistemas Inteligentes de Transporte Chile. (s.f.). *Descripción ITS*. Recuperado el 15 de Abril de 2016, de <http://www.itschile.cl/paginas/descripcion.html>
- Sovani, S. (2017). Fast-Tracking Advanced Driver Assistance Systems (ADAS) and Autonomous Vehicles Development with Simulation. *ANSYS*.

- SULIMAN, C., CRUCERU, C., & MOLDOVEANU, F. (2010). Kalman Filter Based Tracking in an Video Surveillance System. *International Conference on DEVELOPMENT AND APPLICATION SYSTEMS*.
- Thombre, D., & Nirmal, J. (2009). Human Detection and Tracking using Image Segmentation and Kalman Filter. *IAMA*.
- TRACK. (2017). *Sistemas ADAS - Seguridad y Eficiencia para su Flota*. Obtenido de <http://www.tracksurveying.com/automocion/adas-mobileye/>
- Viola, P., & Jones, M. (2004). Robust real-time face detection. *IJCV*.
- Walk, S., Nikodem, M., & Schindler, K. (2010). New Features and Insights for Pedestrian Detection. *CVPR*.
- Wang, X., & Han, T. (2009). An hog-lbp human detector with partial occlusion. *ICCV*.
- Welch, G., & Bishop, G. (2001). An Introduction to the Kalman Filter.
- Wojek, C., & Schiele, B. (2008). A Performance Evaluation of Single and. *DAGM*.
- Wojek, C., & Schiele, B. (2008). A Performance Evaluation of Single and multi-feature people detection. *DAGM*.
- Wu, J., Geyer, C., & Rehg, J. (Mayo de 2011). Time human detection Using-Contour Cues. *IEEE*.
- Xiang, Y., Alahi, A., & Savarese, S. (s.f.). Learning to Track: Online Multi-Object Tracking by Decision Making. Obtenido de http://cvgl.stanford.edu/papers/xiang_iccv15.pdf
- Xu, F., & Gao, M. (2010). Human detection and tracking based on HOG and Particle Filter. *IEEE*.
- Xu, F., Lui, X., & Fujimura, K. (2005). Pedestrian Detection and Tracking With Night Vision. *IEEE*, 6.
- Xu, Y., Cao, X., & Li, T. (August de 2009). Extended Kalman Filter Based Pedestrian Localization for Collision Avoidance. *International Conference on Mechatronics and Automation*, 9-12.
- Yan, J., Zhang, X., & Lei, Z. (2013). Robust Multi-Resolution Pedestrian Detection in Traffic Scenes. *CVPR*.
- Yilmaz, A., Shafique, K., & Lobo, N. (2001). Target-tracking in flir imagery using mean-shift and global motion compensation. *IEEE*. Obtenido de http://www.vision.eecs.ucf.edu/papers/yilmaz_cvbvs_2001.pdf
- Zeng, X., Ouyang, W., & Wnag, X. (2013). Multi-Stage Contextual Deep Learning for Pedestrian Detection. *ICCV*.
- Zhang, S., & Bauckhage, C. (2014). Informed haar-like features improve. *CVPR*.

Zhang, S., Benenson, R., & Schiele, B. (2015). Filtered Channel Features for Pedestrian Detection. *Computer Vision and Pattern Recognition*.

Zitnick, L., Park, D., & Ramanan, D. (2013). Exploring Weak Stabilization for Motion Feature Extraction. *CVPR*.

ANEXOS

Anexo 1

Modelo gráfico de Adaboost, compuesto por tres clasificadores débiles y sus respectivos α en 2D

Donde el símbolo + representa a la clase peatón y el símbolo - representa la clase no peatón.

$$H_{\text{final}} = \text{sign} \left(\alpha_1 \begin{array}{|c|c|c|} \hline - & - & - \\ \hline + & - & - \\ \hline \end{array} + \alpha_2 \begin{array}{|c|c|c|} \hline + & + & - \\ \hline + & + & - \\ \hline - & - & - \\ \hline \end{array} + \alpha_3 \begin{array}{|c|c|c|} \hline + & + & - \\ \hline - & + & - \\ \hline - & - & - \\ \hline \end{array} \right)$$

$$= \begin{array}{|c|c|c|} \hline + & + & - \\ \hline + & - & - \\ \hline + & - & - \\ \hline \end{array}$$