



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 INGENIERO EN ELECTRÓNICA,
AUTOMATIZACIÓN Y CONTROL**

**TEMA: SISTEMA AUTOMÁTICO DE DETECCIÓN Y
RECONOCIMIENTO DE SEÑALES DE TRÁNSITO EN
INTERSECCIONES VIALES PARA APLICACIONES EN
VEHÍCULOS INTELIGENTES**

**AUTORES: CONLAGO GUATEMAL, CRISTIAN ROBERTO
YUNDA SANGOLUISA, JHONNY ALEXANDER**

DIRECTOR: Ing. FLORES CALERO, MARCO JAVIER PhD.

SANGOLQUÍ

2016



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

CERTIFICACIÓN

Certifico que el trabajo de titulación, **“SISTEMA AUTOMÁTICO DE DETECCIÓN Y RECONOCIMIENTO DE SEÑALES DE TRÁNSITO EN INTERSECCIONES VIALES PARA APLICACIONES EN VEHÍCULOS INTELIGENTES”** realizado por los señores **CRISTIAN ROBERTO CONLAGO GUATEMAL** y **JHONNY ALEXANDER YUNDA SANGOLUISA**, 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 los señores **CRISTIAN ROBERTO CONLAGO GUATEMAL** y **JHONNY ALEXANDER YUNDA SANGOLUISA** para que lo sustenten públicamente.

Sangolquí, 07 de Noviembre del 2016

Ing. Marco Javier Flores Calero PhD.
DIRECTOR



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

AUTORÍA DE RESPONSABILIDAD

Nosotros, **CRISTIAN ROBERTO CONLAGO GUATEMAL**, con cédula de identidad N° 1724676661 y **JHONNY ALEXANDER YUNDA SANGOLUISA** con cédula de identidad N° 1722176128, declaramos que este trabajo de titulación “**SISTEMA AUTOMÁTICO DE DETECCIÓN Y RECONOCIMIENTO DE SEÑALES DE TRÁNSITO EN INTERSECCIONES VIALES 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 nos declaramos responsables del contenido, veracidad y alcance de la investigación mencionada.

Sangolquí, 07 de Noviembre del 2016

Cristian Roberto Conlago Guatemal
CC: 1724676661

Jhonny Alexander Yunda Sangoluisa
CC: 1722176128



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

AUTORIZACIÓN

Nosotros, **CRISTIAN ROBERTO CONLAGO GUATEMAL** y **JHONNY ALEXANDER YUNDA SANGOLUISA**, autorizamos a la Universidad de las Fuerzas Armadas ESPE publicar en la biblioteca Virtual de la institución el presente trabajo de titulación **“SISTEMA AUTOMÁTICO DE DETECCIÓN Y RECONOCIMIENTO DE SEÑALES DE TRÁNSITO EN INTERSECCIONES VIALES PARA APLICACIONES EN VEHÍCULOS INTELIGENTES”** cuyo contenido, ideas y criterios son de nuestra autoría y responsabilidad.

Sangolquí, 07 de Noviembre de 2016

Cristian Roberto Conlago Guatemal
CC: 1724676661

Jhonny Alexander Yunda Sangoluisa
CC: 1722176128

DEDICATORIAS

A mis padres, Enma y Roberto por ser pilares fundamentales en mi vida, quienes a lo largo de mi vida han velado por mi bienestar y educación brindándome su apoyo en todo momento. Sus consejos y enseñanzas me han formado como persona con valores, principios, empeño para conseguir mis objetivos. Su lucha incansable ha hecho de ellos un gran ejemplo a seguir, no solo para mí, sino para mis hermanas y familia en general.

A mis hermanas Vicky y Jeseña, por haberme motivado a seguir adelante, por comprenderme en los momentos difíciles que hemos pasado y a pesar de las adversidades de la vida siempre nos hemos mantenido como una familia unida brindándonos apoyo mutuamente.

A cada uno de los que son parte de mi familia, por brindarme su apoyo incondicional que me han ayudado a culminar con éxito esta etapa de mi vida.

Cristian Roberto Conlago Guatemal

DEDICATORIAS

A mi madre Hilda, quien me ha educado y amado, enseñándome valores que me han servido para ser mejor cada día, y gracias a su sacrificio he conseguido culminar esta meta en mi vida.

A mi abuelita Fanny, que es como mi segunda madre, quien me crio y gracias a sus consejos y ejemplo, he aprendido a esforzarme por conseguir mis objetivos.

A mis tíos Néstor, Cesar y Miguel, quienes han sido como mis padres, aconsejándome y enseñando valores fundamentales para ser mejor profesional y sobre todo mejor persona.

A mi tía Nancy y a Karo, quienes me han brindado su apoyo incondicional durante toda mi vida.

Por eso y mucho más, este logro va por todos ustedes.

Jhonny Alexander Yunda Sangoluisa

AGRADECIMIENTOS

Agradezco a Dios por haberme dado vida y salud, lo que me permitió seguir adelante día a día en este largo camino con las fuerzas necesarias para superar obstáculos y dificultades a lo largo de toda mi vida.

A mis padres, por haberme apoyado y motivado mi formación académica, por estar presentes en todo momento y por todos los sacrificios que han hecho por mis hermanas y por mí y. A mi hermana Vicky, por brindarme su apoyo incondicional. A mi hermana Jeseña, por cuidarme y escucharme durante gran parte de mi vida.

A todos los que forman parte de mi familia, en especial a la familia Lara Guatemala por haberme recibido en su hogar y hacerme sentir como un integrante más de su hogar, permitiéndome compartir momentos únicos junto a ellos.

Gracias a mis amigos de la universidad, por compartir momentos de alegría y angustia durante toda la carrera universitaria, a mi compañero en este trabajo de titulación Jhonny por haber compartido sus conocimientos para lograr con éxito la culminación de este proyecto.

Agradezco de manera especial a mi tutor Marco Flores por dedicar parte de su valioso tiempo en el desarrollo de este trabajo. Por haber compartido sus conocimientos, experiencias y amistad, y así poder concluir con éxito mi carrera.

Cristian Roberto Conlago Guatemala

AGRADECIMIENTOS

Quiero agradecer a mi familia, en especial a mi madre y a mi abuelita por educarme y apoyarme, por todo el esfuerzo que han hecho para que nunca me falte nada, sin ustedes no hubiera podido culminar mi carrera, y por haber compartido momentos muy importantes de mi vida, les quedare eternamente agradecido.

Agradezco a la Universidad de las Fuerzas Armadas-ESPE y a todo su cuerpo docente, por haberme formado académicamente con grandes estándares de calidad educativa, y un agradecimiento especial para el Dr. Marco Flores, por haber confiado en nosotros para el desarrollo de este proyecto, por compartir su conocimiento y sus acertados consejos.

Agradezco a los amigos que he hecho a lo largo de mi vida, en especial a mis compañeros de la universidad, con los que se han compartido grandes momentos y quien más que ellos para entender el sacrificio que se ha hecho para poder culminar esta carrera, y agradezco especialmente a Cristian por su gran apoyo y colaboración en la elaboración de este proyecto.

Jhonny Alexander Yunda Sangoluisa

ÍNDICE DE CONTENIDOS

CERTIFICACIÓN	ii
AUTORÍA DE RESPONSABILIDAD	iii
AUTORIZACIÓN	iv
DEDICATORIAS	v
AGRADECIMIENTOS	vii
ÍNDICE DE CONTENIDOS	ix
ÍNDICE DE TABLAS	xii
ÍNDICE DE FIGURAS	xiv
RESUMEN	xx
ABSTRACT	xxi
CAPÍTULO I	1
1. INTRODUCCIÓN	1
1.1 Antecedentes.....	1
1.2 Accidentes de tránsito.....	2
1.2.1 Accidentes de tránsito en el mundo.....	2
1.2.1.1 Estado actual de la seguridad vial en el mundo.....	3
1.2.2 Accidentes de tránsito en el Ecuador.....	5
1.3 Tipos de señales de tránsito en el Ecuador.....	9
1.3.1 Señales reglamentarias en intersecciones viales.....	11
1.4 Sistemas inteligentes de transporte.....	11
1.4.1 Sistemas avanzados de asistencia a la conducción.....	12
1.4.1.1 Sistemas de reconocimiento de señales de tránsito.....	15
1.5 Justificación e importancia.....	16
1.6 Alcance del proyecto.....	17
1.7 Objetivos.....	19
1.7.1 Objetivo general.....	19
1.7.2 Objetivo específicos.....	19
1.8 Estructura del documento.....	19
CAPÍTULO II	21
2. ESTADO DEL ARTE	21
2.1 Introducción.....	21
2.2 Detección de señales de tránsito.....	21

2.2.1	Detección a través del color	22
2.2.1.1	Segmentación basada en la umbralización del color	22
2.2.1.2	Segmentación basada en el aprendizaje del color	23
2.2.2	Detección a través de la forma	24
2.2.2.1	Detección de forma a través de características de borde	24
2.2.2.2	Detección de forma a través de comparación de patrones	25
2.2.2.3	Detección de forma a través de técnicas de aprendizaje automático	25
2.3	Reconocimiento de señales de tránsito	26
2.3.1	Métodos de extracción de características	26
2.3.2	Algoritmos de clasificación	28
2.3.2.1	Algoritmos de búsqueda de vecinos cercanos	28
2.3.2.2	Algoritmos de aprendizaje automático	29
2.4	Análisis del estado de la técnica	31
CAPÍTULO III.....		33
3.	DETECCIÓN DE SEÑALES DE TRÁNSITO	33
3.1	Introducción	33
3.2	Espacios de color y pre-procesamiento.....	35
3.2.1	Elección del mejor espacio de color	37
3.3	Generación de regiones de interés mediante <i>k – NN</i> usando <i>Km – means</i>	40
3.4	Generación de ROIs y resultados parciales	50
3.5	Conclusiones de la etapa de detección.....	54
CAPÍTULO IV		55
4.	RECONOCIMIENTO DE SEÑALES DE TRÁNSITO DEL ECUADOR	55
4.1	Introducción	55
4.2	Pre-Procesamiento de los Candidatos	56
4.3	Extracción de características usando HOG.....	59
4.3.1	Cálculo del gradiente de la imagen	60
4.3.2	Construcción del histograma de orientación	62
4.3.3	Normalización de los histogramas de orientación	65
4.3.4	Construcción de las características HOG.....	66
4.4	Clasificación usando SVM	68
4.4.1	Entrenamiento y validación del clasificador	69

4.5	Resultados experimentales.....	72
4.6	Conclusiones de la etapa de reconocimiento	76
CAPÍTULO V.....		77
5.	PRUEBAS Y RESULTADOS.....	77
5.1	Introducción	77
5.2	Sistema de percepción, procedimiento y visualización	77
5.3	Pruebas de funcionamiento	79
5.4	Resultados experimentales y análisis.....	84
5.5	Tiempos de cómputo.....	90
5.6	Conclusiones del capítulo	91
CAPÍTULO VI.....		92
6.	CONCLUSIONES Y TRABAJOS FUTUROS	92
6.1	Conclusiones	92
6.2	Trabajos futuros	95
BIBLIOGRAFÍA.....		96

ÍNDICE DE TABLAS

Tabla 1. Principales causas de mortalidad en el Ecuador año 2014.....	7
Tabla 2. Fallecidos por principales causas de accidentes de tránsito a nivel nacional año 2015.....	8
Tabla 3. Análisis del estado de la técnica para la detección de señales de tránsito.	31
Tabla 4. Variación de los valores en los distintos canales de los diferentes espacios de color.	40
Tabla 5. Estimación del número de centroides para el espacio de color RGB normalizado.....	43
Tabla 6. Estimación del número de centroides para el modelo de color Lab.	43
Tabla 7. Elección del parámetro k para el algoritmo de clasificación $k - NN$	48
Tabla 8. Características que debe cumplir una ROI en una imagen de tamaño 640x480.....	50
Tabla 9. Tamaño del vector de características HOG para diferentes orientaciones y tamaño de celda.....	68
Tabla 10. Base de datos con imágenes disponibles para el entrenamiento del clasificador	69
Tabla 11. Conjunto de entrenamiento y validación del clasificador	70
Tabla 12. Resultados de clasificación para clasificadores con características HOG con celdas de 2x2 píxeles.....	75
Tabla 13. Resultados de clasificación para clasificadores con características HOG con celdas de 4x4 píxeles.....	75
Tabla 14. Resultados de clasificación para clasificadores con características HOG con celdas de 8x8 píxeles.....	75
Tabla 15. Resultados de clasificación para clasificadores con características HOG con celdas de 16x16 píxeles.....	76
Tabla 16. Secuencias de video utilizada para las pruebas de funcionamiento.....	81
Tabla 17. Matriz de confusión para días normales.....	87
Tabla 18. Matriz de confusión para días soleados.	87
Tabla 19. Matriz de confusión para días nublados.....	87

Tabla 20. Matriz de confusión para el sistema en general.	87
Tabla 21. Resultados del sistema respecto a la precisión y exactitud.	89
Tabla 22. Tiempos de cómputo del sistema.	90

ÍNDICE DE FIGURAS

Figura 1. Principales causas de muerte a nivel mundial en personas de 15 a 29 años (Organización Mundial de la Salud, 2015).	3
Figura 2. Número de muertes por accidentes de tránsito en el mundo (Organización Mundial de la Salud, 2015).	4
Figura 3. Muertes por accidentes de tránsito y vehículos de motor matriculados en base a su nivel de ingreso económico (Organización Mundial de la Salud, 2015).	4
Figura 4. Número de accidentes de tránsito terrestre en el Ecuador durante los años 2001-2010 (Agencia Nacional de Tránsito, 2012).	6
Figura 5. Número de muertos en accidentes de tránsito en Ecuador durante los años 2001-2010 (Agencia Nacional de Tránsito, 2012).	6
Figura 6. Comparación de personas fallecidas y lesionadas en accidentes de tránsito años 2014 – 2015 (Agencia Nacional de Tránsito, 2016).	8
Figura 7. Principales señales de tránsito del Ecuador: (a) reglamentarias, (b) informativas de servicios, (c) preventivas, (d) informativas de destinos, turismo, riesgo (Agencia Nacional de Tránsito, 2010).	10
Figura 8. Principales señales en intersecciones viales: (a) Pare, (b) Ceda el paso (Agencia Nacional de Tránsito, 2010).	11
Figura 9. Principales sistemas avanzados de asistencia a la conducción: (a) sistema de navegación a bordo, (b) control de crucero adaptativo, (c) asistencia de cambio de carril, (d) sistema de advertencia de cambio de carril, (e) reconocimiento de señales de tránsito, (f) control de luces adaptativo, (g) visión nocturna, (h) sistema de aparcamiento automático (Mendieta, 2013).	13
Figura 10. Sistemas de reconocimiento de señales de tránsito: (a) sistema incorporado en el tablero de instrumentos, (b) sistema desarrollado para Smartphone. (Mercedes-Benz, s.f.), (iTunes, 2016).	16
Figura 11. Esquema propuesto para la detección y reconocimiento de señales de tránsito en intersecciones viales.	18

Figura 12. Principales problemas en la detección y reconocimiento de señales de tránsito: (a) y (b) oclusiones parciales, (c) y (d) variación de condiciones meteorológicas y de iluminación, (e) y (f) deterioro de las señales de tránsito, (g) y (h) similitud de colores en las escenas.	34
Figura 13. Esquema propuesto para la detección de señales de tránsito.	35
Figura 14. Ejemplos de variación en la iluminación en diferentes días: (a) Normal, (b) Oscuro, (c) Soleado.	36
Figura 15. Aplicación de los espacios de color en las señales de tránsito Pare (superior) y Ceda el Paso (inferior): (a) Imagen original, (b) Lab, (c) RGB normalizado, (d) HSV, (e) HSL, (f) YCrCb.	36
Figura 16. Aplicación del filtro de mediana: (a) Imagen original, (b) Imagen filtrada.	37
Figura 17. Distribución del color rojo en el espacio RGB: (a) R-G, (b) R-B, (c) G-B.	37
Figura 18. Distribución del color rojo en el espacio YCrCb: (a) Y-Cr, (b) Y-Cb, (c) Cr-Cb.	38
Figura 19. Distribución del color rojo en el espacio Lab: (a) L-a, (b) canal L-b, (c) a-b.	38
Figura 20. Distribución del color rojo en el espacio RGB normalizado: (a) Rn-Gn, (b) Rn-Bn, (c) Gn-Bn.	38
Figura 21. Distribución del color rojo en el espacio HSV, canales: (a) H-S, (b) H-V, (c) S-V.	39
Figura 22. Distribución del color rojo en el espacio HSL, canales: (a) H-L, (b) H-S, (c) L-S.	39
Figura 23. Ejemplos de algoritmos utilizados para la segmentación del color rojo: (a) algoritmo de clasificación $k - NN$, (b) algoritmo de agrupamiento de datos $Km - means$	41
Figura 24. Distribución del color de interés y no interés del espacio en los espacios de color: (a) RGB normalizado, (b) Lab.	42
Figura 25. Curvas ROC para determinar el número de centroides (Km) en los espacios de color: (a) RGB normalizado, (b) Lab.	44

- Figura 26.** Métodos de elección del número Km para el algoritmo $Km - means$, para el espacio RGB normalizado: (a) y (b) Calinski-Harabasz, (c) y (d) Davies-Bouldin, (e) y (f) Gap (g) y (h) Silhouettes; para la clase de interés y no interés respectivamente..... 45
- Figura 27.** Métodos de elección del número Km para el algoritmo $Km - means$, para el espacio Lab: (a) y (b) Calinski-Harabasz, (c) y (d) Davies-Bouldin, (e) y (f) Gap, (g) y (h) Silhouettes; para la clase de interés y no interés respectivamente. 46
- Figura 28.** Distribución de los centroides de los espacios de color: (a) RGB normalizado, componentes Gn-Bn; (b) Lab, componentes a-b..... 47
- Figura 29.** Curvas ROC para determinar el valor de k , para el algoritmo de clasificación $k - NN$, sobre el espacio de color RGB normalizado..... 48
- Figura 30.** Segmentación de las señales Pare (superior) y Ceda el Paso (inferior) utilizando el algoritmo $k - NN$, en el espacio de color RGB normalizado: (a) Imagen original, (b) $k = 3$, (c) $k = 4$ 49
- Figura 31.** Curva ROC para el clasificador final $k - NN$ con el valor de $k = 3$, y con valores de Km de 30 y 40 para la clase de interés y de no interés respectivamente..... 49
- Figura 32.** Resultados de la generación de ROIs de las señales Pare y Ceda el Paso para un día de iluminación normal: (a) imagen original, (b) aplicación del filtro de mediana, (c) imagen en el espacio RGB normalizado, (d) segmentación, (e) resultado de aplicar la erosión a (d), (f) resultado de aplicar la dilatación a (e), (g) eliminación de cuerpos que no cumplen con especificaciones de área y relación largo/ancho, (h) ROIs para la etapa de clasificación..... 51
- Figura 33.** Resultados de la generación de ROIs de las señales Pare y Ceda el Paso para un día soleado: (a) imagen original, (b) aplicación del filtro de mediana, (c) imagen en el espacio de color RGB normalizado, (d) segmentación, (e) resultado de aplicar la erosión a (d), (f) resultado de aplicar la dilatación a (e), (g) eliminación de cuerpos que no cumplen con especificaciones de área y relación largo/ancho, (h) ROIs para la etapa de clasificación. 52

- Figura 34.** Resultados de la generación de ROIs de las señales Pare y Ceda el Paso para un día oscuro: (a) imagen original, (b) aplicación del filtro de mediana, (c) imagen aplicada el espacio de color RGB normalizado, (d) segmentación, (e) resultado de aplicar la erosión a (d), (f) resultado de aplicar la dilatación a (e), (g) eliminación de cuerpos que no cumplen con especificaciones de área y relación largo/ancho, (h) ROIs para la etapa de clasificación..... 53
- Figura 35.** Esquema propuesto para el reconocimiento de señales de tránsito. 55
- Figura 36.** Resultados de la etapa de detección: (a) imagen original identificada las ROIs, (b) ROIs en imágenes independientes. 56
- Figura 37.** Transformación a escala de grises en señales de Ceda el Paso (izquierda) y Pare (derecha): (a) imágenes originales, (b) imágenes en escala de grises. 57
- Figura 38.** Escalamiento de imágenes: (a) imágenes originales, (b) imágenes escaladas a 32x32 píxeles. 57
- Figura 39.** Ecuilización de histograma en señales de Ceda el paso (arriba) y Pare (abajo): (a) imágenes originales, (b) histogramas de imágenes originales, (c) imágenes ecualizadas, (d) histogramas de imágenes ecualizadas. 58
- Figura 40.** Estructura de características HOG (Dalal & Triggs, 2005). 60
- Figura 41.** Aplicación filtros diferenciales en señales de Pare (arriba) y Ceda el Paso (abajo): (a) imágenes originales, (b) imágenes de componentes verticales del gradiente GV , (c) imágenes de componentes horizontales del gradiente GH 61
- Figura 42.** Cálculo del gradiente en señales de Pare (arriba) y Ceda el Paso (abajo): (a) imágenes originales, (b) imágenes del módulo del gradiente MG , (c) imágenes de la orientación del gradiente OG 61
- Figura 43.** División de una imagen en 25 celdas; 5 celdas verticales y 5 celdas horizontales. 62
- Figura 44.** Construcción de histograma de orientación: (a) intervalos de orientación, (b) histograma de orientación. 63

- Figura 45.** Tamaños de celdas a utilizar: (a) 2x2 píxeles, (b) 4x4 píxeles, (c) 8x8 píxeles, (d) 16x16 píxeles..... 64
- Figura 46.** Intervalos de orientación del gradiente a utilizar: (a) 3 intervalos, (b) 6 intervalos, (c) 9 intervalos, (d) 12 intervalos, (e) 15 intervalos. 64
- Figura 47.** Cálculo de histograma de gradientes orientados en señales de ceda el paso (arriba) y pare (abajo): (a) imágenes originales divididas en 4 celdas, (b) histograma de gradientes orientados por celda con 9 orientaciones..... 65
- Figura 48.** Normalización de histograma: (a) obtención de bloque, (b) histogramas de las celdas del bloque, (c) concatenación de histogramas, (d) histograma normalizado. 66
- Figura 49.** Construcción de las características HOG: (a) desplazamiento del bloque en la imagen, (b) concatenación de los histogramas para obtener un vector de 324 elementos..... 67
- Figura 50.** Características HOG en señales de Pare (arriba) y Ceda el Paso (abajo): (a) imágenes originales, (b) características HOG con celdas de 8x8 píxeles, bloques de 2x2 celdas y 9 orientaciones..... 68
- Figura 51.** Base de datos disponible: (a) muestras con señales de Ceda el Paso, (b) muestras con señales de Pare, (c) muestras negativas 70
- Figura 52.** Curvas ROC para clasificadores con características HOG con celdas de 2x2 píxeles (izquierda) y 4x4 píxeles (derecha): (a) Núcleo Lineal, (b) Núcleo Polinómico, (b) Núcleo Gaussiano. 73
- Figura 53.** Curvas ROC para clasificadores con características HOG con celdas de 8x8 píxeles (izquierda) y 16x16 píxeles (derecha): (a) Núcleo Lineal, (b) Núcleo Polinómico, (b) Núcleo Gaussiano. 74
- Figura 54.** Sistema de percepción, procesamiento y visualización utilizada en el proyecto..... 78
- Figura 55.** Integración del sistema en un vehículo: (a) instalación del sistema de percepción, visualización y procesamiento, (b) pruebas en tiempo real. 78
- Figura 56.** Pruebas de funcionamiento en condiciones iluminación soleado para señales de pare (izquierda) y ceda el paso (derecha): (a) imagen

original, (b) generación de las regiones de interés, (c) respuesta del sistema.....	79
Figura 57. Pruebas de funcionamiento en condiciones iluminación normal para señales de pare (izquierda) y ceda el paso (derecha): (a) imagen original, (b) generación de las regiones de interés, (c) respuesta del sistema.....	80
Figura 58. Pruebas de funcionamiento en condiciones iluminación nublado para señales de pare (izquierda) y ceda el paso (derecha): (a) imagen original, (b) generación de las regiones de interés, (c) respuesta del sistema.....	81
Figura 59. Pruebas de funcionamiento en escenarios complejos para señales de pare (izquierda) y ceda el paso (derecha): (a) imagen original, (b) generación de las regiones de interés, (c) resultado del sistema.	82
Figura 60. Pruebas de funcionamiento con oclusiones parciales para señales de pare (izquierda) y ceda el paso (derecha): (a) imagen original, (b) generación de las regiones de interés, (c) resultado del sistema.	83
Figura 61. Pruebas de funcionamiento con deterioro para señales de pare (izquierda) y ceda el paso (derecha): (a) imagen original, (b) generación de las regiones de interés, (c) resultado del sistema.	84
Figura 62. Respuestas del sistema: (a) real positivo, (b) falso negativo, (c) falso positivo, (d) real negativo.....	85
Figura 63. Tipos de detección: (a) ventana de la posición verdadera, (b) detección con $AD = 1$, (c) detección con $AD > 0.5$, (d) múltiple detección con $AD > 0.5$, (e) detección con $AD < 0.5$, (f) detección con $AD = 0$	86
Figura 64. Curva DET del funcionamiento del sistema total y para diferentes días con distintas condiciones de iluminación.....	90

RESUMEN

En la actualidad miles de personas se ven afectadas por los accidentes de tránsito en el mundo y en el Ecuador, por lo cual se están desarrollando nuevas tecnologías que buscan hacer la conducción más segura a través de los Sistemas Avanzados de Asistencia a la Conducción (ADAS). Esta investigación contempla el desarrollo de un sistema automático de detección y reconocimiento de señales de tránsito en intersecciones viales, enfocándose en las señales de Pare y Ceda el Paso. El proceso de detección consiste en extraer las regiones de interés (ROIs) que contienen a los posibles candidatos a ser una señal de tránsito, en esta etapa se utilizó el espacio de color RGB normalizado, la segmentación está basada la clasificación del color rojo mediante el algoritmo $k - NN$, para determinar los parámetros óptimos de funcionamiento de esta etapa se utilizaron las curvas ROC, obteniendo una precisión en la clasificación de color en la etapa de detección del 98.60%. La etapa de reconocimiento está formado por la extracción de características, utilizando una modificación HOG utilizando diferentes tamaños de bloques y orientaciones, y el clasificador SVM. Para determinar las parámetros óptimos del clasificador se utilizó las curvas ROC, obteniendo una clasificación en la etapa de reconocimiento del 99.57%. El sistema ha sido puesto a prueba en tiempo real en diferentes condiciones de iluminación sobre las carreteras del Ecuador, con una precisión del 96%, medido a través de la curva DET.

Palabras Clave

- **VEHÍCULOS INTELIGENTES**
- **CLASIFICADOR DEL VECINO MÁS CERCANO**
- **HISTOGRAMA DE GRADIENTES ORIENTADOS**
- **APRENDIZAJE AUTOMÁTICO**
- **VISIÓN ARTIFICIAL**

ABSTRACT

Nowadays thousands of people are affected by traffic accidents in Ecuador and the world, so new technologies are seeking to make driving safer through the Advanced Systems driver assistance being developed (ADAS). This research includes the development of an automatic detection and recognition of traffic signals at intersections, focusing on stop signs and yield. The detection process involves extracting regions of interest (ROIs) containing potential candidates for a traffic signal, at this stage the RGB standard colour space is used, segmentation is based on the classification of red colour by k-NN algorithm, to determine the optimum operating parameters of this stage the ROC curves were used, obtaining a colour classification at detection stage of 98.60%. The recognition stage performs feature extraction with HOG using different block sizes and orientations; the classifier used is SVM to determine the type of traffic signal, to determine the optimum parameters of the classifier ROC curves was used, obtaining a classification the stage of recognition of 99.57%. The system has been tested in real time in different lighting conditions on the roads of Ecuador. The system operating performance was determined with DET curves, obtaining an accuracy of 96%.

Keywords

- **SMART VEHICLES**
- **NEAREST NEIGHBOR CLASSIFIER**
- **HISTOGRAM OF ORIENTED GRADIENTS**
- **MACHINE LEARNING**
- **ARTIFICIAL VISION**

CAPÍTULO I

1. INTRODUCCIÓN

1.1 Antecedentes

Una gran cantidad de personas se ven afectadas debido a los accidentes de tránsito, motivo por el cual se está desarrollando nuevas tecnologías que buscan hacer la conducción más segura a través de los Sistema Avanzado de Asistencia a la Conducción (ADAS, por sus siglas en inglés) (Li, Sun, Liu, & Wang, 2015). Los ADAS son sistemas inteligentes diseñados principalmente para mejorar la seguridad vial y el confort en la conducción. Algunos ejemplos de tales sistemas incluyen sistemas de protección de peatones, control de cruce, sistemas de comunicación vehicular, sistemas de navegación, información del tránsito, entre otros. Un sistema de detección y reconocimiento de señales de tráfico (TSDR, del inglés, Traffic Sign Detection and Recognition) (Mammeri, Boukerche, & Almulla, 2013) es un componente esencial de los ADAS, estos sistemas deben tener rápida adquisición y un potente método de detección de señales de tránsito.

Los sistemas actuales están lejos de ser perfectos, debido a algunos desafíos y problemas, como las características del equipo de adquisición de imágenes, condiciones no satisfactorias del camino, señales de tránsito en mal estado, condiciones meteorológicas y movimientos vibratorios del coche (Mammeri, Boukerche, & Almulla, 2013).

Grandes empresas automovilísticas como Ford, Bosch, Mercedes Benz entre otras han incursionado en el desarrollo de sistemas de reconocimiento de señales de tránsito, incorporando en sus últimos modelos estos sistemas, y en algunos casos siendo limitados exclusivamente para Europa. En el Ecuador no existen proyectos relacionados a esta temática, por tanto se propone el desarrollo de un sistema automático de detección y reconocimiento de señales de tránsito especializado en intersecciones viales existentes en el país.

La detección y reconocimiento de estas señales resulta un reto importante en el campo de la investigación contemporánea, para la creación de múltiples aplicaciones para el desarrollo de vehículos autónomos e inteligentes, que brinden seguridad y confort.

La visibilidad de las señales de tránsito es otro factor significativo para la seguridad. Por lo cual, deben presentar un estado óptimo de visibilidad; una señal colocada en un lugar erróneo puede provocar múltiples accidentes de tránsito. Los principales factores que provocan accidentes están: estado del conductor, vehículos en mal estado, peatones cruzando por lugares no autorizados, mal estado de la vía, condiciones meteorológicas adversas, etc. Es por eso que la capacidad de detectar y reconocer las señales viales no evitará todos los accidentes, pero tendrá una influencia positiva en la mejora de la seguridad vial (Lillo Castellano J. M., 2010)

1.2 Accidentes de tránsito

Un accidente de tránsito es un suceso eventual que altera la actividad de personas, vehículos y usuarios viales que se encuentra en una carretera, alterando el orden regular y ocasionando daños (Real Academia Española, 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.).

1.2.1 Accidentes de tránsito en el mundo

En septiembre de 2015, la OMS adoptó los Objetivos de Desarrollo Sostenible (ODS) para la seguridad vial, con el fin de reducir a la mitad el número de muertes y traumatismos por accidentes de tránsito hasta el 2020. “Los accidentes de tránsito son

una de las causas de muerte más importantes en el mundo, y la principal causa de muerte entre personas de edades comprendidas entre los 15 y 29 años” (Organización Mundial de la Salud, 2015, p.3). La **Figura 1** muestra las estadísticas de esta realidad.




Figura 1. Principales causas de muerte a nivel mundial en personas de 15 a 29 años (Organización Mundial de la Salud, 2015).

1.2.1.1 Estado actual de la seguridad vial en el mundo

El número de muertes debido a los accidente de tránsito desde el año 2007, ha tenido una estabilización, pese al aumento mundial de la población y el uso de vehículos motorizados. Entre los años 2010 y 2013, la población ha aumentado en un 4% y los vehículos en un 16%, por lo que se puede afirmar que las medidas de seguridad vial establecidas en los últimos años han salvado vidas humanas. (Organización Mundial de la Salud, 2015), datos que se aprecian en la **Figura 2**.




Figura 2. Número de muertes por accidentes de tránsito en el mundo (Organización Mundial de la Salud, 2015).

En el informe se indica que el 90% de las muertes por accidentes de tránsito se producen en países de ingresos bajos y medios, pese a que en estos países se concentran solo un poco más de la mitad vehículos a nivel mundial (54% de vehículos) (Organización Mundial de la Salud, 2015), en la **Figura 3** se muestra el porcentaje de accidentes de acuerdo a los ingresos de la población.




Figura 3. Muertes por accidentes de tránsito y vehículos de motor matriculados en base a su nivel de ingreso económico (Organización Mundial de la Salud, 2015).

Además, el informe muestra que los vehículos vendidos en el 80% de los países del mundo no cumplen con normas básicas de construcción referentes a la seguridad vial, esto se da principalmente en países de ingresos bajos o medios, donde se produjo en 2014 cerca del 50% de vehículos nuevos a nivel mundial. Dentro de los grupos más

vulnerables a los accidentes de tránsito, el informe muestra que las muertes que se acontecen en las carreteras se produce entre los siguientes usuarios: motociclistas (23%), peatones (22%) y ciclistas (4%) (Organización Mundial de la Salud, 2015).

Los principales factores que ponen en riesgo la seguridad vial en el mundo son (Organización Mundial de la Salud, 2016):

- **Velocidad excesiva, conducción bajo los efectos del alcohol, no usar cinturones de seguridad:** El incumplimiento de estas medidas de seguridad se relaciona directamente con la probabilidad de que ocurra un accidente de tránsito y con la gravedad de las consecuencias de este.
- **Distracciones al conducir:** Se producen muchos tipos de distracciones los cuales alteran el modo de conducir. Los conductores que se distraen al momento de conducir pueden tener diversos efectos adversos como: tiempo de reacción más lento durante el frenado y para reaccionar frente a las señales de tránsito.
- **Irrespeto a las señales de tránsito:** El conducir irrespetando a las señales de tránsito es otra de las causas que producen un accidente, este tema está relacionado directamente a las distracciones al momento de conducir.

1.2.2 Accidentes de tránsito en el Ecuador

De acuerdo a la Secretaría de la Comunidad Andina de Naciones, el número de accidentes de tránsito en el periodo de los años 2005 – 2015 se ha incrementado (Agencia Nacional de Tránsito, 2016). En la **Figura 4**, se observa un aumento considerable en el número de siniestros ocasionadas principalmente debido a las malas prácticas de los usuarios viales, entre las cuales se destacan las distracciones del conductor y el irrespeto a las señales de tránsito (semáforos, pare, ceda el paso) (Agencia Nacional de Tránsito, 2016).




Figura 4. Número de accidentes de tránsito terrestre en el Ecuador durante los años 2001-2010 (Agencia Nacional de Tránsito, 2012).

Además la Agencia Nacional de Tránsito, realizó un informe acerca del número de personas fallecidas durante la década comprendida entre los años 2005-2015, en el cual se da a conocer que en el año 2005 existió un total de 1387 personas fallecidas, mientras que en 2015 se registraron 2138 defunciones. En la **Figura 5** se puede apreciar este incremento de muertes por accidentes de tránsito en el Ecuador durante los años 2005 -2015 (Agencia Nacional de Tránsito, 2016).

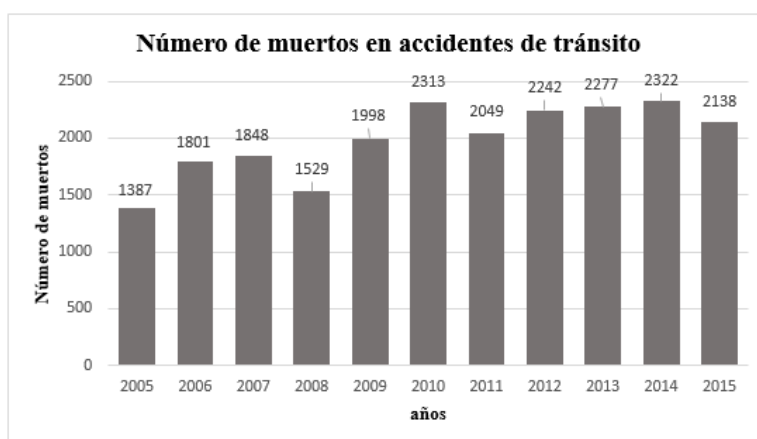


Figura 5. Número de muertos en accidentes de tránsito en Ecuador durante los años 2001-2010 (Agencia Nacional de Tránsito, 2012).

En la actualidad existe mínima concientización por parte de los conductores y usuarios viales, es así que el Instituto Nacional de Estadística y Censo (INEC) con datos del año 2014, informa que la sexta causa de mortalidad en el país lo constituyen los accidentes de transporte terrestre con un total de 3059 fallecidos que equivale a un 4.86% de muertes (Instituto Nacional de Estadística y Censo, s.f.) (Véase **Tabla 1**).

Tabla 1.

Principales causas de mortalidad en el Ecuador año 2014.

Causa de muerte	Número de fallecidos	%	Tasa de mortalidad
Enfermedades isquémicas del corazón	4430	7.03	27.64
Diabetes Mellitus	4401	6.99	27.46
Enfermedades cerebrovasculares	3777	6.00	23.57
Enfermedades hipertensivas	3572	5.67	22.29
Influenza y neumonía	3412	5.43	21.33
Accidentes de transporte terrestre	3059	4.86	19.09

Fuente: (Instituto Nacional de Estadística y Censo, n.d.).

La Agencia Nacional de Tránsito, en el informe de rendición de cuentas anual de siniestros y víctimas de tránsito, compara los sucesos ocurridos entre los años 2014 y 2015, en el cual se puede observar una reducción 8% en fallecidos y 8% en lesionados (Agencia Nacional de Tránsito, 2016). Además, se indica que la tasa de mortalidad por cada 100.000 habitantes en el 2015, fue de 12,94, mientras que, en el año 2014, fue de 14,49; esto refleja una reducción del 1.55 de fallecidos debido a accidentes de tránsito. Para el caso de lesionados en el año 2014 se registraron 27668 personas, mientras que para el 2015 se registraron 25375 personas, en la **Figura 6** se puede observar las comparaciones de los años.

De acuerdo con la Agencia Nacional de Tránsito para datos hasta diciembre del año 2015 entre las principales causas que ocasionaron accidentes de tránsito en dicho año, en donde existieron personas fallecidas se establecen de acuerdo a lo que se muestra en la **Tabla 2**, esta tabla indica que el 8.14% de accidentes de tránsito ocurridos en el año 2015 corresponden al irrespeto de las señales de tránsito (pare,

ceda el paso y semáforos), con un total de 174 personas fallecidas (Agencia Nacional de Tránsito, 2016).




Figura 6. Comparación de personas fallecidas y lesionadas en accidentes de tránsito años 2014 – 2015 (Agencia Nacional de Tránsito, 2016).

Tabla 2.

Fallecidos por principales causas de accidentes de tránsito a nivel nacional año 2015.

Causa	Total personas	%
Conducir desatento a las condiciones de tránsito (pantallas de video, comida, maquillaje o cualquier otro elemento distractor)	382	17,77
Conducir vehículo superando los límites máximos de velocidad	282	13,19
No transitar por las aceras o zonas de seguridad destinadas para el efecto	181	8,47
No respetar las señales reglamentarias de tránsito (pare, ceda el paso, luz roja del semáforo)	174	8,14
Conduce bajo la influencia de alcohol, sustancias estupefacientes o psicotrópicas y/o medicamentos	146	6,83
No ceder el derecho de vía o preferencia de paso al peatón	140	6,55

Fuente: (Agencia Nacional de Tránsito, 2016).

Para el año 2016, de acuerdo con la Agencia Nacional de Tránsito con información de los meses de enero-mayo se conoce que se produjeron 803 fallecimientos por accidentes de tránsito, las principales causas con sus correspondientes porcentajes de ocurrencia son (Agencia Nacional de Tránsito, 2016):

- Conducir desatento a las condiciones de tránsito (elementos distractores): 40,47%
- Superar los límites máximos de velocidad: 13.45%
- No respetar las señales reglamentarias (pare, ceda el paso, luz roja del semáforo): 4,86%

1.3 Tipos de señales de tránsito en el Ecuador

Las señales de tránsito tienen como objetivo el de advertir a los usuarios sobre anomalías en las carreteras, regular el tránsito e informar sobre aspectos relevantes que intervienen en la circulación vial. Existe un gran número de señales de tránsito vigentes en la normativa ecuatoriana, las cuales son: manuales, luminosas, acústicas, verticales y horizontales (Agencia Nacional de Tránsito, 2010). La **Figura 7** muestra los grupos en los que se clasifican las principales señales verticales utilizadas en la regulación de tránsito en el Ecuador.

La señalización vertical se refiere a todas las señales colocadas en forma vertical en relación al pavimento, es un dispositivo de control de tránsito que es usado para brindar información específica a los usuarios de la vía a través de una palabra o leyenda con símbolos (Agencia Nacional de Tránsito, 2010). Las señales presentan formas y colores muy llamativos con la finalidad de hacerlas perfectamente distinguibles para todos los usuarios viales.




Figura 7. Principales señales de tránsito del Ecuador: (a) reglamentarias, (b) informativas de servicios, (c) preventivas, (d) informativas de destinos, turismo, riesgo (Agencia Nacional de Tránsito, 2010).

Las señales de tránsito en el Ecuador se clasifican de la siguiente manera (Agencia Nacional de Tránsito, 2010):

- **Señales reglamentarias:** Informan a los usuarios viales las prioridades en el uso de las mismas, así como las prohibiciones y obligaciones. Estas señales son de color rojo.
- **Señales preventivas:** Se utilizan para alertar a los conductores de potenciales peligros que se encuentran en la carretera. Indican la necesidad de tomar precauciones y requieren de una reducción de la velocidad de circulación o de realizar alguna otra maniobra. Estas señales son de color amarillo.
- **Señales de información:** Tienen como propósito orientar y guiar a los usuarios, indicando la información necesaria para que puedan llegar a sus

destinos de la forma más simple, segura y directa posible. Los colores de estas señales son: azul, verde y naranja.

1.3.1 Señales reglamentarias en intersecciones viales

Las señales de tránsito reglamentarias Pare y Ceda el Paso sobresalen por la importancia para brindar seguridad a los usuarios viales. En la **Figura 8** se muestran estas señales de tránsito, las cuales tienen las siguientes características (Agencia Nacional de Tránsito, 2010):

- **Pare:** Se instala en las aproximaciones a las intersecciones donde una de las vías tiene prioridad respecto a la otra, obliga a detener completamente el vehículo.
- **Ceda el paso:** Se utiliza en aproximaciones a intersecciones donde el tráfico que debe ceder el paso tiene una buena visibilidad sobre el tráfico de la vía principal, no obliga a detenerse si el flujo vehicular de la vía principal permite incorporarse al tránsito con seguridad. Se utiliza en redondeles y aproximaciones por vías secundarias a una intersección.




Figura 8. Principales señales en intersecciones viales: (a) Pare, (b) Ceda el paso (Agencia Nacional de Tránsito, 2010).

1.4 Sistemas inteligentes de transporte

Los sistemas inteligentes de transporte (ITS, por sus siglas en inglés Intelligent Transportation Systems) se definen como “sistemas de transporte que utilizan los

avances tecnológicos en el área de las telecomunicaciones, la informática y el control para apoyar las operaciones y seguridad en el transporte y la gestión del tránsito” (Sistemas Inteligentes de Transporte Chile, s.f.), los cuales surgen en los años 90 como una solución a los problemas generados por el incremento del uso del transporte terrestre, en el sector urbano e interurbano (Universidad de Barcelona, 2004).

Los servicios que prestan los ITS tienen como meta reducir la contaminación ambiental, reducir el número de accidentes de tránsito y minimizar la congestión vehicular, y a su vez también el mejoramiento de utilización de la vía, ayudar a los conductores a conducir evitando producir congestión y accidentes de tránsito (Ministerio de Transportes y Comunicaciones del Perú, s.f.), tales servicios se mencionan a continuación:

- Sistemas avanzados de información al viajero
- Sistemas avanzados de gestión de transporte
- Sistemas avanzados de transporte público
- Operaciones de vehículos comerciales
- Sistemas avanzados de control vehicular
- Sistemas avanzados de transporte rural
- Sistemas avanzados de asistencia a la conducción

La mayoría de servicios de ITS se enfocan en entorno al tráfico y ambientes externos como la carretera, pero existe un grupo el cual se enfoca en el vehículo y a su vez en el conductor, los cuales se denominan sistemas avanzados de asistencia a la conducción o comúnmente denominados ADAS.

1.4.1 Sistemas avanzados de asistencia a la conducción

Los sistemas avanzados de asistencia a la conducción tienen como propósito proporcionar información adicional del entorno al conductor, alertar sobre situaciones potencialmente peligrosas e incluso actuar ante dichas situaciones para evitar accidentes (Jiménez, y otros, 2011). Entre los sistemas ADAS que actualmente existen están los de la **Figura 9**, que son los siguientes (Mendieta, 2013):




Figura 9. Principales sistemas avanzados de asistencia a la conducción: (a) sistema de navegación a bordo, (b) control de crucero adaptativo, (c) asistencia de cambio de carril, (d) sistema de advertencia de cambio de carril, (e) reconocimiento de señales de tránsito, (f) control de luces adaptativo, (g) visión nocturna, (h) sistema de aparcamiento automático (Mendieta, 2013).

- **Sistema de navegación a bordo:** Es un sistema que ofrece el posicionamiento del vehículo en la carretera y proporciona información del tráfico por medio de GPS.
- **Control de crucero adaptativo:** Se encarga de realizar el control automático de velocidad del vehículo para mantener una distancia segura con respecto a los vehículos que se encuentra en frente para evitar una colisión.
- **Asistencia de cambio de carril:** Son sistemas destinados a observar los ángulos muertos producidos a los lados laterales de los vehículos, advirtiendo la presencia de otros vehículos a su alrededor.
- **Sistema de advertencia de abandono de carril:** Es un sistema que advierte al conductor cuando el vehículo empieza a salirse de su carril sin accionar las luces direccionales previamente.
- **Sistema anticolidión:** Son sistemas que busca evitar las colisiones laterales o frontales, para lo cual detecta obstáculos, peatones u otros vehículos, y actúa sobre el freno si es necesario.
- **Adaptación de velocidad inteligente:** Es un sistema que monitorea los límites de velocidad permitidos en la carretera y advierte al conductor o actúa sobre el vehículo en el caso que se sobrepasen los límites permitidos.
- **Reconocimiento de señales de tránsito:** Es un sistema que detecta y reconoce las señales de tránsito presente en entornos viales y advierte al conductor de la presencia de las mismas.
- **Control de luces adaptativo:** Este sistema actúa sobre las luces del vehículo, en respuesta a las variaciones del entorno, su función es mejorar la visibilidad del conductor y evitar la contaminación lumínica.
- **Visión nocturna:** Son sistemas que utiliza la emisión infrarroja, invisible para el ojo humano, mostrando el camino por medio de una pantalla, mejorando la visibilidad del conductor en la oscuridad.
- **Control de descenso:** Es un sistema que permite el descenso suave y controlado en pendientes o terrenos irregulares, sin la necesidad de accionar el freno.

- **Detección de somnolencia en el conductor:** Son sistemas que por medio de una cámara actúan sobre la cara del conductor, advirtiéndole si el mismo muestra signos de cansancio, somnolencia o distracción.
- **Sistemas de comunicación vehicular:** Son sistemas que permiten transmitir información sobre el tráfico o advertencias de seguridad con aquellos vehículos que circulan en las inmediaciones.
- **Sistema de aparcamiento automático:** Son sistemas que ayudan al conductor a ejecutar las maniobras necesarias para estacionarse, teniendo en cuenta factores como distancias, espacios de parqueo libre, hasta el movimiento del volante para un estacionamiento preciso.

1.4.1.1 Sistemas de reconocimiento de señales de tránsito

Los sistemas de reconocimiento de señales de tránsito existentes en la actualidad poseen una cámara ubicada en la parte posterior del espejo retrovisor e incorporan una pantalla en el tablero de instrumentos o en las pantallas de los sistemas de radio y navegación de los vehículos que permiten observar el entorno vial. Estos sistemas producen una señal audible al momento del reconocimiento de una señal de tránsito para evitar la distracción del conductor (El tiempo, 2008).

La mayoría de sistemas de reconocimiento de señales se enfocan principalmente en reconocer las señales de límites de velocidad, como es el caso de las empresas automovilísticas Mercedes Benz y Ford. Mercedes Benz posee un sistema que reconoce las señales de prohibición de adelantamiento (Mercedes-Benz, s.f.).

La empresa alemana Bosch ha incursionado en los sistemas de reconocimiento de señales de tránsito a través de Smartphones, desarrollando una aplicación IOS denominada “myDriveAssist” capaz de detectar límites de velocidad, prohibición de adelantar y señales de fin de prohibiciones, la aplicación se encuentra disponible en países europeos como España, Alemania, Austria, Suiza, Francia y el Reino Unido (iTunes, 2016). En la **Figura 10** se observan las interfaces de los sistemas de reconocimiento de señales de tránsito.



Figura 10. Sistemas de reconocimiento de señales de tránsito: (a) sistema incorporado en el tablero de instrumentos, (b) sistema desarrollado para Smartphone. (Mercedes-Benz, s.f.), (iTunes, 2016).

1.5 Justificación e importancia

El alto número de accidentes de tránsito ocurridos en el Ecuador a causa de la imprudencia e irrespeto de las señales reglamentarias por parte del conductor, constituyen el principal motivo para el desarrollo de este proyecto de titulación. Debido al aumento de la población y de los vehículos motorizados (Organización Mundial de la Salud, 2015), las necesidades impuestas por la sociedad requieren respuestas inteligentes las cuales demandan del uso de tecnologías y conocimientos más complejos, que den soluciones a la mayoría de necesidades en la seguridad vial de la población en el Ecuador y el mundo.

En la actualidad no existe concientización por parte de los conductores y demás usuarios viales sobre los daños materiales y pérdida de vidas humanas que pueden ocasionar los accidentes de tránsito, es así que el INEC, con datos del año 2014, informa que la sexta causa de mortalidad en nuestro país lo constituyen los accidentes de transporte terrestre con un total de 3059 fallecidos lo cual equivale a un 4.86% de muertes en el Ecuador durante ese año (Instituto Nacional de Estadística y Censo, s.f.).

La ANT del Ecuador con datos del año 2015, indica que las principales causas de accidentes de tránsito en el Ecuador se dan por una mala actitud del conductor, esto se demuestra en los datos proporcionado por la ANT los que indican que las principales causas que provocaron accidentes de tránsito en los cuales hubo personas fallecidas se

debe a: conducir desatento a las condiciones de tránsito y no respetar las señales reglamentarias (Agencia Nacional de Tránsito, 2016).

Esta investigación se presenta con la finalidad de que en un futuro se pueda mejorar la seguridad vial en el Ecuador reduciendo los efectos de la distracción e irrespeto de las señales reglamentarias de tránsito por parte del conductor, mediante la aplicación de tecnologías relacionadas a la visión e inteligencia artificial aplicados en el sector automotriz, esto se puede lograr mediante la detección de señales de tránsito en intersecciones viales, de esta manera se puede crear un sistema avanzado para la asistencia en la conducción.

1.6 Alcance del proyecto

En el presente trabajo de investigación, se plantea el desarrollo de un sistema automático de detección y reconocimiento de señales de tránsito en intersecciones viales para aplicaciones en vehículos inteligentes. Al tratarse de intersecciones viales el estudio se centra en las señales de Pare y Ceda el Paso.

El sistema se encuentra compuesto por dos etapas: detección (también conocida como segmentación) y reconocimiento, en la **Figura 11** se observa el esquema del sistema propuesto.

La primera etapa del proyecto consiste en el estudio de las señales de tránsito de color rojo, para lo cual se desarrolla un análisis de los espacios de color con el objetivo de elegir el/los espacios de color que permita la generación de regiones de interés, en ambientes variables de iluminación, bajo condiciones reales.

La siguiente parte del proyecto se centra en el estudio de las técnicas de reconocimiento de patrones, para lo cual se seleccionan las técnicas más adecuadas referente a descriptores de imágenes y clasificadores, para esto se desarrolla un algoritmo que permita clasificar los candidatos a señales de tránsito, provenientes del algoritmo de detección; en este punto, se usaran patrones de entrenamiento para el

aprendizaje del algoritmo para tener una mejor discriminación entre señales de Pare, Ceda el Paso, o cualquier otro objeto.

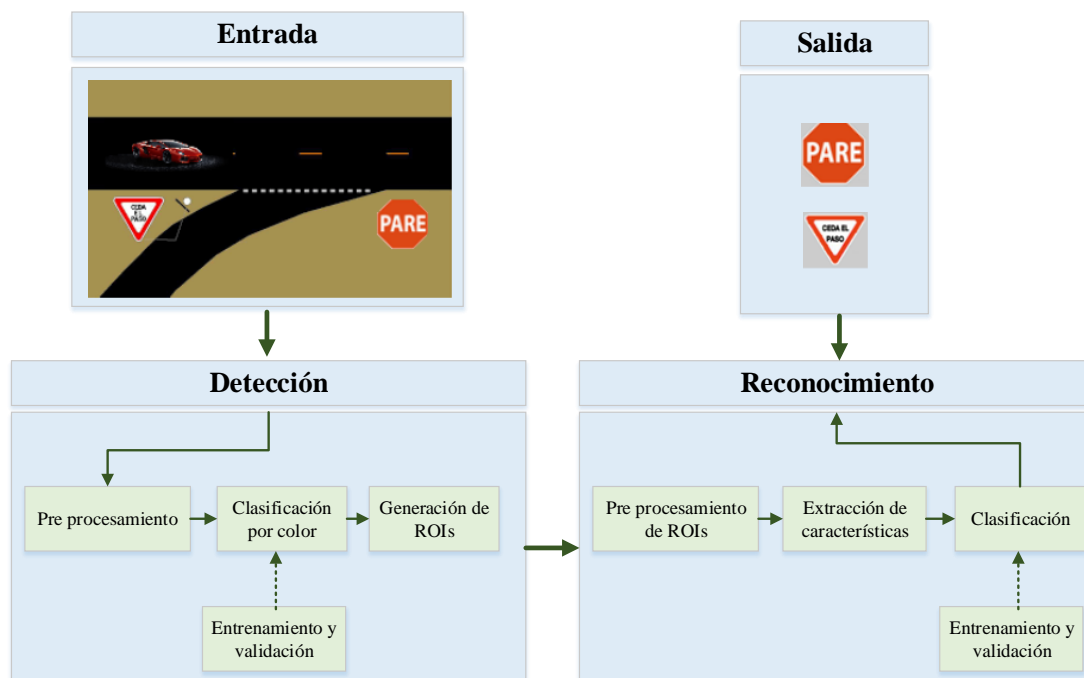


Figura 11. Esquema propuesto para la detección y reconocimiento de señales de tránsito en intersecciones viales.

La etapa final del proyecto se centra en las pruebas de funcionamiento del sistema, para lo cual se implementará un aparato portátil de adquisición de imágenes de fácil instalación en vehículos, con la finalidad de obtener secuencia de imágenes en tiempo real para desarrollar y obtener los resultados que permitirá observar el desempeño de esta propuesta.

La aplicación será capaz de detectar las señales de “Pare” y “Ceda el Paso” en un rango de distancias de 5 a 20 metros antes de la intersección. Para alertar al conductor de la presencia de cualquiera de las señales de tránsito, el sistema dispondrá de una alarma auditiva al momento de reconocer una señal, además de mostrar en pantalla la imagen de la señal detectada.

Finalmente, el presente proyecto presenta el desarrollo de los algoritmos computacionales que permitirán un avance en el estudio de los sistemas inteligentes de transporte, y este proyecto será base para futuras investigaciones en este campo,

porque servirá para crear nuevas metodologías en los sistemas de asistencia a la conducción, principalmente en el Ecuador.

1.7 Objetivos

1.7.1 Objetivo general

- Desarrollar un sistema automático para la detección de señales de tránsito Pare y Ceda el Paso en intersecciones viales del Ecuador para aplicaciones en vehículos inteligentes

1.7.2 Objetivo específicos

- Elaborar un algoritmo mediante el estudio de los espacios de color, para la detección automática de las regiones de interés en imágenes.
- Elaborar un algoritmo para el reconocimiento automático de las señales de tránsito utilizando descriptores y clasificadores de objetos.
- Implementar un sistema móvil de adquisición de imágenes de fácil instalación en cualquier vehículo para la detección de señales de tránsito en intersecciones viales.
- Desarrollar pruebas de funcionamiento en tiempo real para medir el desempeño del sistema.

1.8 Estructura del documento

La estructura del presente documento se compone de varios capítulos, los cuales tienen la siguiente estructura:

El capítulo 1 corresponde a la introducción de la problemática de los accidentes de tránsito en el Ecuador, y la revisión de algunos sistemas comerciales desarrollados.

En el capítulo 2 se presenta el estado del arte, donde se describe las técnicas utilizadas para la detección de señales de tránsito. El estado del arte se lo realiza para la etapa de detección y para la etapa de reconocimiento.

El capítulo 3 describe el algoritmo desarrollado para la detección de señales de tránsito. En la primera parte se analiza los escenarios en donde trabajará el sistema. En la segunda parte se realiza un estudio de los espacios de color para contrarrestar los efectos de la iluminación. Como parte final del capítulo se realiza la segmentación del color rojo para determinar los candidatos a señales de tránsito.

En el capítulo 4 se presenta el algoritmo de reconocimiento del sistema. El método utilizado para la extracción de característica y la técnica utilizada para la clasificación de las señales de tránsito se detallan en este capítulo, para lo cual se realiza el entrenamiento de varios clasificadores con diferentes características del descriptor de imagen y diferentes parámetros propios de cada clasificador.

El capítulo 5 muestra el análisis de resultados del desempeño del sistema para pruebas de funcionamiento en tiempo real y para días con condiciones meteorológicas y de iluminación adversas.

Finalmente, en el capítulo 6 se presentan las conclusiones a las que se ha llegado al realizar este trabajo de titulación, también se incluyen trabajos futuros que se pretende seguir desarrollando en este campo de investigación.

CAPÍTULO II

2. ESTADO DEL ARTE

2.1 Introducción

En la actualidad con el avance de la tecnología, se han desarrollado varios e importantes trabajos relacionados con los temas de detección y reconocimiento de señales de tránsito, cada uno de estos trabajos han aportado soluciones parciales al problema global con la finalidad de mejorar el confort y la seguridad de los usuarios viales.

En el trabajo de (Møgelmoose, Liu, & Trivedi, 2015) se concluye que el algoritmo que produce los mejores resultados globales de un TSDR comprende dos etapas: detección y reconocimiento, para lo cual el estudio del estado del arte se centrara en estas dos fases, finalmente se realizará un análisis de todas las técnicas existentes para determinar cuáles son las mejores.

2.2 Detección de señales de tránsito

La detección es un proceso para extraer o separar los objetos que conforman las regiones de interés (ROI, del inglés Region of Interest), del medio en el que se encuentran, tiene como objetivo principal la generación de candidatos para ser enviados a la etapa de clasificación (Lillo Castellano J. M., 2010).

La detección está basada en dos principios fundamentales: similitud y discontinuidad (Pajares & de la Cruz, 2002), (Lillo Castellano J. M., 2010).

- **Similitud:** detección orientada a regiones, los píxeles del objeto en estudio tienen valores similares de un atributo de interés.
- **Discontinuidad:** detección orientada a bordes, los objetos se diferencian del entorno presentando fronteras y contornos bien definidos.

Existen dos métodos principales para la detección de señales, los cuales son: detección basada en el color y detección a través de la forma (Mammeri, Boukerche, & Almulla, 2013), los mismos que se describen a continuación.

2.2.1 Detección a través del color

Los métodos de detección basadas en el color tienen como objetivo segmentar los colores de los objetos con el fin de proporcionar ROIs para la etapa de reconocimiento. La segmentación de color consiste en dividir una imagen en subconjuntos de píxeles conectados que comparten propiedades de color similares (Mammeri, Boukerche, & Almulla, 2013). En un estudio realizado en (Gómez Moreno, Maldonado Bascón, Gil Jiménez, & Lafuente Arroyo, 2010), analizan dos métodos de segmentación de señales de tránsito basados en la segmentación a través del color: segmentación en base a umbral del color y segmentación basada en el aprendizaje del color.

2.2.1.1 Segmentación basada en la umbralización del color

La técnica consiste básicamente en que cada píxel con un valor por encima de un cierto valor (umbral) se marca con una etiqueta apropiada. Existen diversos trabajos que utilizan esta técnica de segmentación, así (Nguwi & Kouzani, 2008) utiliza el espacio de color HSI para contrarrestar los efectos de iluminación y realizan la segmentación en base a distintos umbrales que tienen que ser modificados debido a los cambios de iluminación especialmente en los días soleados.

En el trabajo desarrollado por (Zaklouta & Stanciulescu, Real-Time Traffic-Sign Recognition Using Tree Classifiers, 2012), (Salti, Petrelli, Tombari, Fioraio, & Di Stefano, 2015), utilizan el método de umbralización para segmentar señales de tránsito de color rojo utilizando la ecuación (1), y para el color azul utiliza la ecuación (2). El umbral determinado empíricamente es: $\mu \pm 4\sigma$, en donde μ y σ , son la media y desviación estándar del conjunto de píxeles de la imagen.

$$R' = \max\left(0, \frac{\min(R - G, R - B)}{R + G + B}\right) \quad (1)$$

$$B' = \max\left(0, \frac{B - R}{R + G + B}\right) \quad (2)$$

En (Greenhalgh & Mirmehdi, 2012) utilizan el espacio de color RGB normalizado para contrarrestar los efectos de iluminación, para la segmentación utilizan el método basado en la umbralización y utilizan el método MSER (maximally stable extremal regions- regiones extremas máximamente estables) para detectar las posibles ROIs, esta técnica ofrece robustez frente a las variaciones en la iluminación de las escenas.

2.2.1.2 Segmentación basada en el aprendizaje del color

El uso de las técnicas de aprendizaje automático proporciona mejoras respecto a los métodos basados en la umbralización, pero a un costo computacional mayor (Mammeri, Boukerche, & Almulla, 2013). Un algoritmo basado en máquinas de soporte de vectores (SVM, del inglés Support Vector Machine) fue realizado en (Gómez Moreno, Maldonado Bascón, Gil Jiménez, & Lafuente Arroyo, 2010) para clasificar píxeles de acuerdo a la información del color. Además, se muestra que la segmentación basada en aprendizaje de color produce mejores resultados que los métodos de segmentación basados en la umbralización.

En (Kellmeyer & Zwahlen, 1994) utilizan las redes neuronales (NN, Neural Networks), para segmentar las imágenes en función del color, en este trabajo se utiliza la NN para clasificar ocho colores y generar las posibles ROIs, después son analizadas por una segunda red neuronal para determinar si la forma corresponde a una posible señal de tránsito.

En el trabajo desarrollado en (Lillo Castellano, Mora Jiménez, Figuera Pozuelo, & Rojo Álvarez, 2015), desarrollaron un sistema de segmentación de señales de color rojo, amarillo, azul, verdes y blancas basados en la clasificación del color, en el cual

utilizan las componentes a y b del espacio de color Lab para minimizar los efectos de la iluminación, con el conjunto de muestras se utiliza el algoritmo $K_m - means$ para modelar dichas componentes, luego utiliza el algoritmo de clasificación $k - NN$ (k-Nearest Neighbors) para segmentar los colores rojo, azul, amarillo y verde.

2.2.2 Detección a través de la forma

La forma de los señales también puede ser utilizada para detectar los posibles candidatos, especialmente cuando las técnicas basadas en el color fallan, por ejemplo cuando existen cambios bruscos en la iluminación. El método consiste en la extracción de todas las formas parecidas a las señales de tránsito (círculos, triángulos, rectángulos, cuadrados, etc.) que se encuentran en el ambiente para la generación de ROIs (Mammeri, Boukerche, & Almulla, 2013).

2.2.2.1 Detección de forma a través de características de borde

La mayoría de los detectores de forma se basan en la detección de contornos, para ello utilizan: la Transformada de Hough (HT) y el algoritmo Fast Radial Symmetry (FRS) (Mammeri, Boukerche, & Almulla, 2013). Por ejemplo, (Aoyagi & Asakura, 1996) aplican el filtro Laplaciano en la imagen para extraer los contornos y bordes.

La HT comúnmente se utiliza para detectar las formas parecidas a las señales de tránsito que se encuentran en la imagen. Por ejemplo, los autores en (Kuo & Lin, 2007) utiliza la HT para la fase de detección y la combinan con un proceso de filtrado de mediana para disminuir el conjunto de candidatos. Sin embargo, esta técnica sigue siendo computacionalmente costosa.

La técnica FRS es una variante de la HT circular. Se extendió a las señales de tránsito con la finalidad de obtener detectores para diversas formas. En (Loy & Barnes, 2004) se utiliza para detectar formas triangulares, cuadradas y octogonales. En comparación con HT, esta técnica computacionalmente es más rápida, lo que permite

crear sistemas que funcionen en tiempo real. Como el algoritmo se basa en la detección de formas es robusto frente a cambios de iluminación.

2.2.2.2 Detección de forma a través de comparación de patrones

La detección de forma a través de la comparación de patrones (TM, por siglas en inglés de Template Matching), se utiliza para buscar en la imagen formas iguales a la de las señales de tránsito a través de plantillas y determinar las posibles señales de tránsito. Sin embargo, la aplicación de estas técnicas no es adecuada para sistemas de tiempo real, ya que requieren alto costo computacional para comparar la forma encontrada con las plantillas existentes (Mammeri, Boukerche, & Almulla, 2013). La aplicación de esta técnica en la detección de forma de señales de tránsito en general tiene un buen rendimiento frente a cambios de iluminación en el ambiente. Sin embargo, es sensible a las oclusiones y rotaciones (Ruta, Li, & Liu, 2010).

2.2.2.3 Detección de forma a través de técnicas de aprendizaje automático

Las NN y SVM se utilizan generalmente para la detección de formas parecidas a las señales de tránsito (Mammeri, Boukerche, & Almulla, 2013). Por ejemplo (Fang, Chen, & Fuh, 2003) desarrollaron un sistema de detección constituido por dos NN: la primera, se entrena para clasificar cada pixel por su color; la segunda, se utiliza para la detección de las ROIs por la forma basada en las señales de tránsito, esta técnica tienen un buen rendimiento en condiciones meteorológicas y de iluminación adversas, la desventaja de esta técnica es que computacionalmente es muy costosa.

En (Maldonado-Bascón, Lafuente-Arroyo, Gil-Jiménez, Gómez-Moreno, & López-Ferreras, 2007) utilizan SVM lineal para la detección de forma de señales de tránsito. Este método es invariante a la rotación, la escala, y funciona bajo oclusiones parciales.

En otro trabajo realizado por (Li, Sun, Liu, & Wang, 2015), presentan un modelo de color Gaussiano, para obtener un modelo de color invariante a la iluminación en

escenas reales. Para la segmentación de la imagen en diferentes regiones se utiliza el algoritmo $K_m - means$ (Duda, Hart, & Stork, 2001), para agrupar los píxeles conectados entre sí y determinar los posibles candidatos para ser enviados a la etapa de clasificación.

2.3 Reconocimiento de señales de tránsito

Esta etapa consiste en identificar a qué tipo de clase pertenecen las ROI's provenientes de la etapa de detección (Carrasco Pascual, 2009), esto se lleva a cabo por medio del reconocimiento de las características propias de cada clase, obtenidas a través de un conjunto de entrenamiento. Las técnicas de reconocimiento a utilizar dependerán de las muestras obtenidas, y los resultados que se desea obtener, para lo cual se esta etapa se divide en dos partes: métodos de extracción de características y algoritmos de clasificación.

2.3.1 Métodos de extracción de características

La extracción de características consiste en encontrar un conjunto de características numéricas que representen la información más relevante de una imagen, con lo cual imágenes parecidas poseerán valores numéricos cercanos, a los métodos de extracción de características normalmente se los denomina “Descriptor de imagen”.

Las señales de tránsito cuentan con formas geométricas definidas y con bordes de alto contraste, por lo que (Greenhalgh & Mirmehdi, 2012) utilizan los Histogramas de Gradientes Orientados (HOG, por sus siglas en inglés) para describir señales de tránsito a través de la forma, para a las ROIs se re-escala a un tamaño de 24x24 píxeles, utilizando el filtro de Sobel para encontrar las componentes de gradiente en las ROIs, y así formar histogramas para 9 orientaciones por cada celda, y se utilizan bloques normalizados con solapamiento simple para mejorar el contraste de forma local. Se calcularon las características HOG de señales que tienen forma circular, triangular, triangular invertida y rectangular.

En el trabajo de (Salti, Petrelli, Tombari, Fioraio, & Di Stefano, 2015) se utiliza HOG, con una variación de las orientaciones del gradiente, con un total de 16 orientaciones sin signo que van de 0° a 180° , para ROIs de 64×64 píxeles de tamaño, con celdas de 8×8 píxeles y bloques de 8×8 celdas, a su vez (Zaklouta & Stanciulescu, Real-Time Traffic-Sign Recognition Using Tree Classifiers, 2012) utiliza HOG como método de extracción de características, con 8 y 9 orientaciones, con un rango de orientación del gradiente de 0° a 180° y 0° a 360° , para evaluar su comportamiento frente a distintos algoritmos de clasificación.

Por otra parte HOG también es utilizado por (Huang, Yu, & Gu, 2014) para ROIs de 15×15 píxeles de tamaño, celdas de 5×5 píxeles, bloques de 10×10 píxeles, solapamiento de 5×5 píxeles, 8 orientaciones, el método fue puesto a prueba en señales de prohibición, señales de peligro, señales reglamentarias, límites de velocidad y otras. Otros autores como (Li, Sun, Liu, & Wang, 2015) utilizan variaciones de HOG, como es el caso de la técnica denominada PHOG que utiliza la HOG tradicional variando su obtención con el método de la pirámide, siendo el método robusto hacia la variación de iluminación, reduciendo considerablemente las falsas alarmas en comparación de HOG tradicional.

Otros descriptores también son utilizados para la extracción de características, como es el caso de la transformada de Fourier utilizada por (Lillo Castellano, Mora Jiménez, Figuera Pozuelo, & Rojo Álvarez, 2015), en el cual se analizan los bordes de las señales de tránsito a través de las componentes de frecuencia de la imagen, las componentes de baja frecuencia aportan información general de la forma de la señal de tránsito, y las componentes de alta frecuencia aportan información detallada de los bordes, en este trabajo se han extraído las características para señales de tránsito con forma: circular, triangular, cuadrada, rectangular, flechas y semicircular, presentando este descriptor invariancia a la escala y la rotación. Por otra parte la transformada de Hough es utilizada por (Fleyeh, Biswas, & Davami, 2013) como método de extracción de características para obtener información de señales preventivas y reglamentarias.

2.3.2 Algoritmos de clasificación

Los algoritmos de clasificación dependerán de las muestras obtenidas, las características a utilizar, y los resultados que se desea obtener, para lo cual se clasifican en dos categorías: búsqueda de vecinos cercanos y aprendizaje (Zaklouta & Stanciulescu, Real-time traffic sign recognition in three stages, 2014)

2.3.2.1 Algoritmos de búsqueda de vecinos cercanos

Los algoritmos de búsqueda de vecinos cercanos se basa en clasificar un objeto o muestra desconocida, encontrado la mayor similitud a una muestra existente en un conjunto de entrenamiento o conocido como “vecino más cercano”, esto se logra encontrando la distancia mínima entre la muestra al vecino más cercano, entre los métodos que utilizan estos algoritmos están la comparación de patrones (template matching) y los clasificadores de árbol como k-d tree y random forest (Michell, 1997) (Zaklouta & Stanciulescu, Real-time traffic sign recognition in three stages, 2014).

La comparación de patrones o template matching es una técnica utilizada para la detectar o reconocer una zona de una imagen como se mencionó anteriormente en las técnicas de detección, que en la etapa de reconocimiento es generalmente una ROI, la técnica compara la ROI con un patrón dado, ese patrón representa al objeto a identificar (Vanrell, s.f.), la principal característica de esta técnica es su robustez a los cambios de iluminación, por lo cual su utilización es ideal en ambientes abiertos (Carrasco Pascual, 2009).

En el trabajo realizado por (Piccioli, De Micheli, Parodi, & Campani, 1996) se propone utilizar el método de reconocimiento de patrones y correlación cruzada, para el reconocimiento de señales de tránsito, enfocándose en encontrar 2 patrones a reconocer, el primer patrón se basa en las señales circulares y el segundo en las señales triangulares, se han re-escalado las ROIs a imágenes de 50x50 píxeles, la desventaja de esta técnica es su alto costo computacional.

El reconocimiento de patrones con desviación estándar fue utilizado por (Zin & Hama, 2004) para el reconocimiento de señales de tránsito circulares a diferentes condiciones de iluminación, y se observó que la técnica es invariante a los cambios de escala, debido a que las pruebas se realizaron en imágenes con un tamaño de 128x128 píxeles, y para muestras con tamaño de 64x64 píxeles se obtuvieron el mismo resultado.

En el trabajo de (Kuo & Lin, 2007) se utiliza clasificadores de árbol, específicamente el clasificador k-d tree, apoyándose de las redes neuronales, con lo cual las redes neuronales se utilizó para identificar el grupo de señal a la que pertenece, sea esta circular, triangular o informativa, y el clasificador k-d tree para identificar el contenido de las señales de tránsito perteneciente a cada grupo, y se determinó que esta técnica presenta robustez a la variación de condiciones de iluminación y deformación, pero utilizando un gran costo computacional, siendo difícil de implementar en aplicaciones en tiempo real.

Random forest es un método que utiliza varios clasificadores de árbol simultáneamente independientes entre ellos, cada clasificador de árbol es construido independientemente usando bootstrap sobre una base de datos, la predicción que este respaldada por la mayoría de clasificadores de árbol es la predicción final y es utilizado por (Kouzani, 2007) para el reconocimiento de señales de tránsito, para lo cual utiliza una base de 2500 imágenes pertenecientes a 15 categorías diferentes, las cuales son utilizadas para el entrenamiento y las pruebas, este método obtuvo buenos resultados a condiciones de ambiente variables.

2.3.2.2 Algoritmos de aprendizaje automático

Los algoritmos de aprendizaje automático comúnmente conocidos como Machine Learning consisten en encontrar la separación óptima entre 2 o más clases, por medio de conjuntos de entrenamiento se logra el aprendizaje del clasificador para obtener una función de separación, los principales métodos de aprendizaje automático son: Support Vector Machine (SVM) (Cortes & Vapnik, 1995) y redes neuronales artificiales

(Ponce Cruz, 2010) (Zaklouta & Stanciulescu, Real-time traffic sign recognition in three stages, 2014).

En el trabajo de (Li, Sun, Liu, & Wang, 2015), utilizan SVM con 1000 muestras para el entrenamiento de señales de tránsito circulares, triangulares, triangulares invertidas y en forma de diamante, para lo cual se ha extraído sus características por medio de la técnica denominada Pirámide de Histograma de Gradientes (PHOG), en la etapa de prueba y validación se utilizó 500 muestras, estas muestras están sometidas a diferentes tipo de iluminación, oclusión y clima variable, con lo cual se obtuvieron buenos resultados para las diferentes señales de tránsito.

Los autores (Greenhalgh & Mirmehdi, 2012) utilizan una casada de clasificadores SVM de tipo uno contra uno para la clasificación de señales de tránsito a través de su forma, para lo cual utilizaron una base de datos con imágenes 131 señales de tránsito y por cada una 1200 imágenes con distorsiones y variaciones aleatorias, de lo cual se obtuvo sus características por medio de HOG, y una etapa de detección por medio de espacios de color, obteniendo buenos resultados en señales de tránsito blancas y de color. Por otra parte (Salti, Petrelli, Tombari, Fioraio, & Di Stefano, 2015) también utiliza SVM y HOG, probando un núcleo gaussiano, para el reconocimiento de señales preventivas, regulatorias y de prohibición.

En el trabajo de (Lillo Castellano, Mora Jiménez, Figuera Pozuelo, & Rojo Álvarez, 2015) utiliza SVM para el reconocimiento de 6 diferentes señales de tránsito y realiza un comparación entre el núcleo lineal y el no lineal, deduciendo que el núcleo con los mejores resultados es el no lineal debido a su baja tasa de pérdidas.


En el trabajo de (Yin, Ouyang, Liu, Guo, & Wei, 2015) utilizan redes neuronales basado en el método de entrenamiento de K-means para la reducción de tiempo de computo, para lo cual se entrenó la red para la clasificación de 43 tipos diferentes de señales de tránsito, previamente se extrae las características de las ROI's por medio de la técnica de Rotation Invariant Binary Patter (RIBP), con lo cual se obtuvo que no posee invariancia a la escala, debido a que la precisión de clasificación disminuyo al aumentar el tamaño de la imagen y también se observa un aumento en el tiempo de computo.

2.4 Análisis del estado de la técnica

Un resumen de las técnicas utilizadas para la detección y reconocimiento de señales de tránsito se muestran en la **Tabla 3**, para la etapa de detección se utilizan técnicas como segmentación mediante la umbralización, detección a través de la forma y clasificación de color siendo esta última técnica la que se utiliza en el presente proyecto; mientras que para la etapa de reconocimiento se observan la utilización métodos de extracción de características y algoritmos de clasificación, en la cual los mejores resultados se los observan en el clasificador SVM, tanto para el caso de la utilización de las técnicas de extracción de características HOG y PHOG, teniendo un costo computacional menor la técnica con HOG y SVM.

Tabla 3.

Análisis del estado de la técnica para la detección de señales de tránsito.

Autores	Técnica de segmentación	Técnica de reconocimiento	Precisión de la técnica	Tiempo de cómputo
(Piccioli, De Micheli, Parodi, & Campani, 1996)	Clasificación del color	Template Matching	98% en general	Tiempo, 500 ms por ROI
(Zin & Hama, 2004)	Umbralización de color	Template Matching con desviación estándar	80% en ambientes diurnos, 57% al atardecer 45% en ambientes nocturnos	No específica
(Kuo & Lin, 2007)	Umbralización del color.	k-d tree	92.45% en señales triangulares, 97.78% en señales circulares, 100% en señales informativas, 95.5% en general	No específica
			CONTINÚA	

(Kouzani, 2007)	Detección a través de la forma.	Random forest	93.9 % en general	No específica
(Li, Sun, Liu, & Wang, 2015)	Aprendizaje automático, para detectar formas.	PHOG y SVM	98.04% en señales circulares, 93.23% en señales triangulares, 96.3% en señales triangulares invertidas 89.4% en señales en forma de diamante	No específica
(Greenhalgh & Mirmehdi, 2012)	Umbralización del color.	HOG y SVM	89.2% en señales de tránsito blancas, 92.1% para señales de color	No específica
(Salti, Petrelli, Tombari, Fioraio, & Di Stefano, 2015)	Clasificación de color	HOG y SVM	98.12% en general	No específica
(Huang, Yu, & Gu, 2014)	No específica	HOG y ELM	95.77% en general	1.5 ms por imagen
(Lillo Castellano, Mora Jiménez, Figuera Pozuelo, & Rojo Álvarez, 2015)	Clasificación de color	Transformada de Fourier y SVM	96.7% en general	No específica
(Yin, Ouyang, Liu, Guo, & Wei, 2015)	Detección a través de la forma	RIBP y Redes Neuronales Artificiales	97.55% en general	No específica

CAPÍTULO III

3. DETECCIÓN DE SEÑALES DE TRÁNSITO

3.1 Introducción

El proceso de detección consiste en extraer las ROIs, para ser enviadas a la etapa de reconocimiento. En la primera parte se aplica un pre-procesamiento de la imagen para reducir el ruido, y luego analizar el desempeño de los espacios de color RGB, Lab, RGB normalizado, YCrCb, HSL y HSV para determinar cuál o cuáles de los espacios ofrecen mayor robustez frente a los cambios de iluminación.


Las señales de tránsito Pare y Ceda el Paso tienen atributos bien diferenciados como son el color, por tal razón la segmentación está basada en la característica del color rojo utilizando el método de clasificación del color mediante el algoritmo $k - NN$. Para reducir el número de ROIs se realiza un pos-procesamiento para eliminar las ROIs que no cumplen ciertas restricciones de formas.

La detección de objetos presenta diversos desafíos, es así que los principales problemas que se tienen en la detección de señales de tránsito se los puede observar en la **Figura 12** y se los detalla a continuación:

- Complejidad de las escenas, debido a la existencia de formas parecidas a las señales, colores similares, lo cual implica gran cantidad de información para procesar demandando mayor tiempo de procesamiento.
- Obstáculos que pueden ocluir parcial o totalmente la señal de tránsito.
- Deterioro de las señales de tránsito
- Diferentes condiciones meteorológicas del entorno, que producen variación de la iluminación.



(a)



(b)



(c)



(d)



(e)



(f)



(g)



(h)

Figura 12. Principales problemas en la detección y reconocimiento de señales de tránsito: (a) y (b) oclusiones parciales, (c) y (d) variación de condiciones meteorológicas y de iluminación, (e) y (f) deterioro de las señales de tránsito, (g) y (h) similitud de colores en las escenas.

La etapa de detección cuenta con las sub-etapas: pre-procesamiento, segmentación y generación de ROIs. La **Figura 13** muestra el esquema propuesto para la etapa de detección de señales de tránsito.

- **Pre-procesamiento:** En esta sub-etapa se realizará el filtrado de la imagen con el objetivo eliminar el ruido, también se transformará a un espacio de color para contrarrestar los efectos de los cambios de iluminación.
- **Segmentación:** Se realizará en base a un método de segmentación basada en la clasificación del color (Mammeri, Boukerche, & Almulla, 2013), en este caso para discriminar el color rojo del resto de colores.
- **Generación de ROIs:** Para la generación de los candidatos a señales de tránsito se utilizan ciertas condiciones de forma como: área, mínima y máxima, relación ancho y alto. Esto con la finalidad de reducir el número de ROIs que se enviarán a la etapa de reconocimiento.




Figura 13. Esquema propuesto para la detección de señales de tránsito.

3.2 Espacios de color y pre-procesamiento

Un gran desafío para la visión artificial son los cambios de iluminación que se presentan en condiciones ambientales reales, para contrarrestar este problema se realiza un estudio de las señales de tránsito en varios espacios de color, con la finalidad de determinar cuál o cuáles ofrece una mayor robustez frente a este problema. En la **Figura 14** se puede observar distintos ambientes de iluminación.

Para ello se toman diferentes muestras de las señales Pare y Ceda el Paso en diferentes ambientes de iluminación, luego se los clasificó en normal, obscuro y soleado. Los espacios de color utilizados fueron: Lab, RGB normalizado, YCrCb, HSV y el HSL. En la **Figura 15** se muestran las señales Pare y Ceda el Paso en los distintos espacios de color.




Figura 14. Ejemplos de variación en la iluminación en diferentes días: (a) Normal, (b) Obscuro, (c) Soleado.

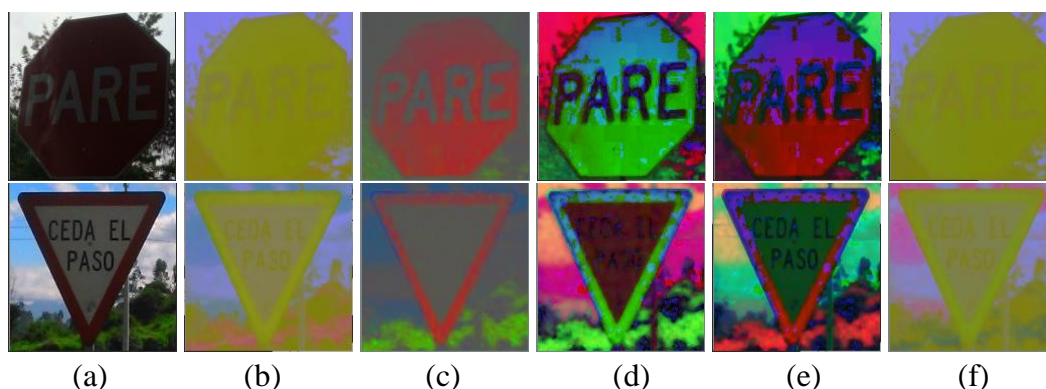


Figura 15. Aplicación de los espacios de color en las señales de tránsito Pare (superior) y Ceda el Paso (inferior): (a) Imagen original, (b) Lab, (c) RGB normalizado, (d) HSV, (e) HSL, (f) YCrCb.

El pre-procesamiento se realiza con la finalidad de eliminar el ruido, para ello se realiza un filtrado en el dominio espacial para operar directamente sobre los píxeles de las imágenes, operando en la vecindad del píxel, aplicando generalmente máscaras de tipo cuadrada o rectangular. La técnica utilizada es el filtro de mediana, este filtro consiste en sustituir el valor del píxel central por el de la mediana de los valores que se encuentran en la máscara (Sucar & Gómez, 2011). En la **Figura 16** se muestra el filtro aplicado en el trabajo para mejorar la calidad de la imagen.




Figura 16. Aplicación del filtro de mediana: (a) Imagen original, (b) Imagen filtrada.

3.2.1 Elección del mejor espacio de color

La elección del mejor espacio de color se basa en el estudio del color rojo de las señales de tránsito, en distintos ambientes de iluminación que corresponde a días soleados, nublados y de iluminación normal. Para determinar el mejor espacio de color se analiza la distribución de las muestras en los distintos espacios de color. Para lo cual, se realiza gráficas en 2D, que muestran la variación de los canales de los modelos de color, los canales que tengan una distribución más uniforme serán aquellos que muestren un mejor desempeño a variaciones en la iluminación del ambiente. El número de muestras utilizadas para el color rojo es de 30000, mientras que para el resto de colores es de 60000. En las **Figura 17 - Figura 22**, se muestran los resultados para cada los canales en cada uno de los espacios de color.

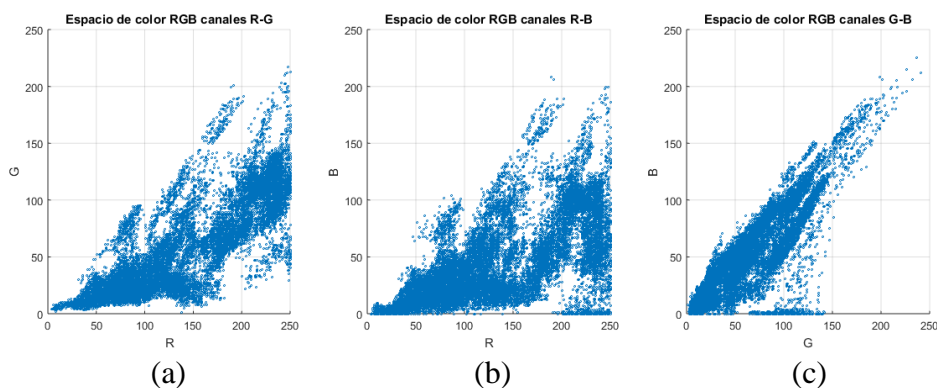


Figura 17. Distribución del color rojo en el espacio RGB: (a) R-G, (b) R-B, (c) G-B.

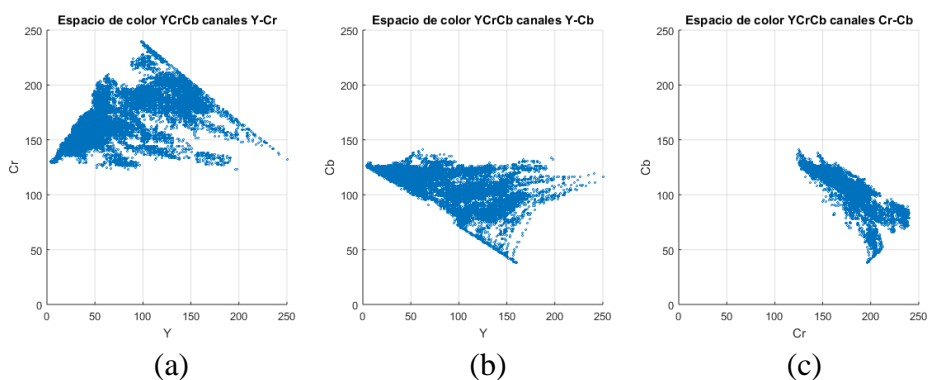


Figura 18. Distribución del color rojo en el espacio YCrCb: (a) Y-Cr, (b) Y-Cb, (c) Cr-Cb.

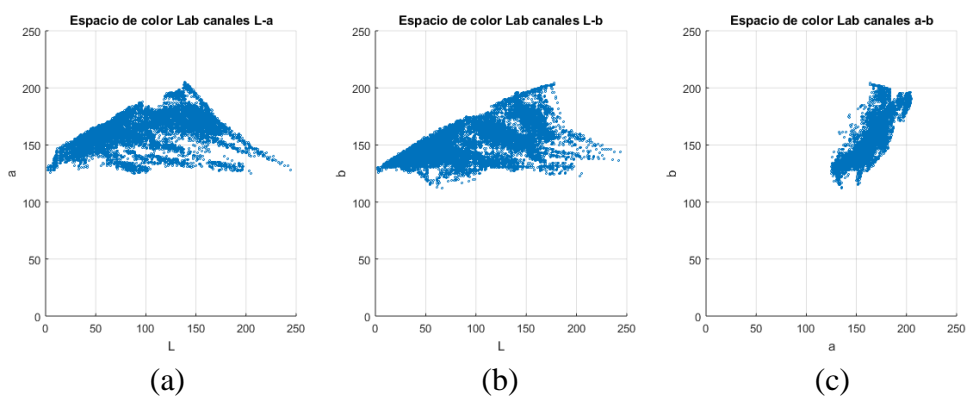


Figura 19. Distribución del color rojo en el espacio Lab: (a) L-a, (b) canal L-b, (c) a-b.

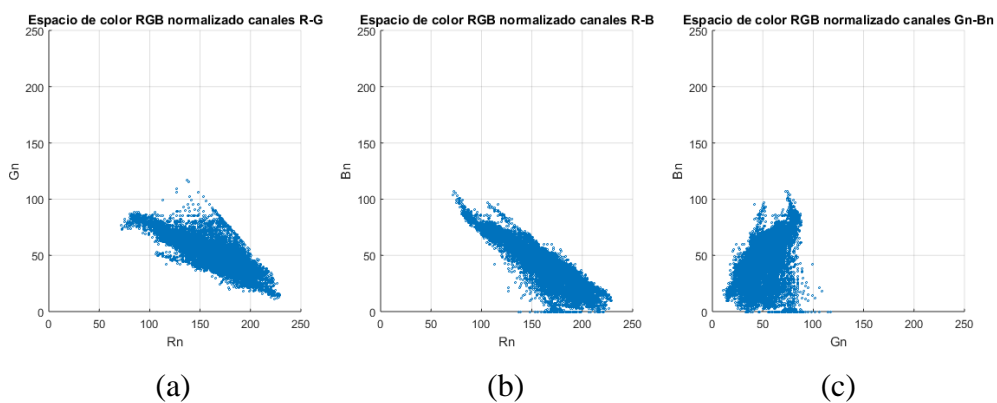


Figura 20. Distribución del color rojo en el espacio RGB normalizado: (a) Rn-Gn, (b) Rn-Bn, (c) Gn-Bn.

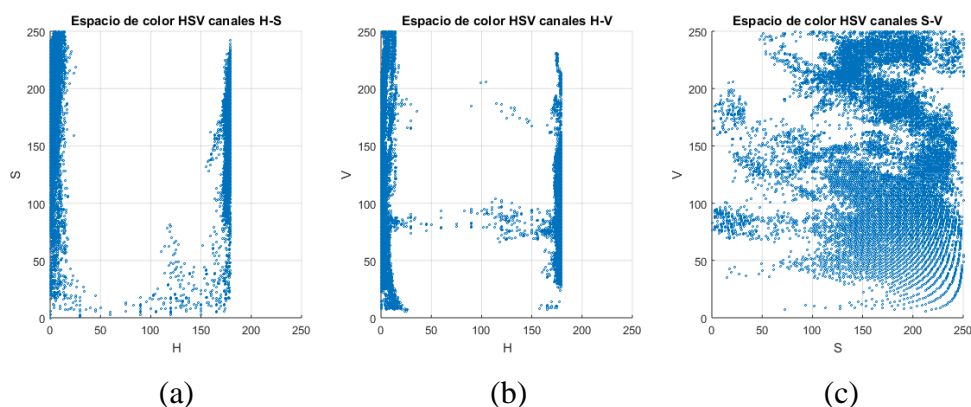


Figura 21. Distribución del color rojo en el espacio HSV, canales: (a) H-S, (b) H-V, (c) S-V.

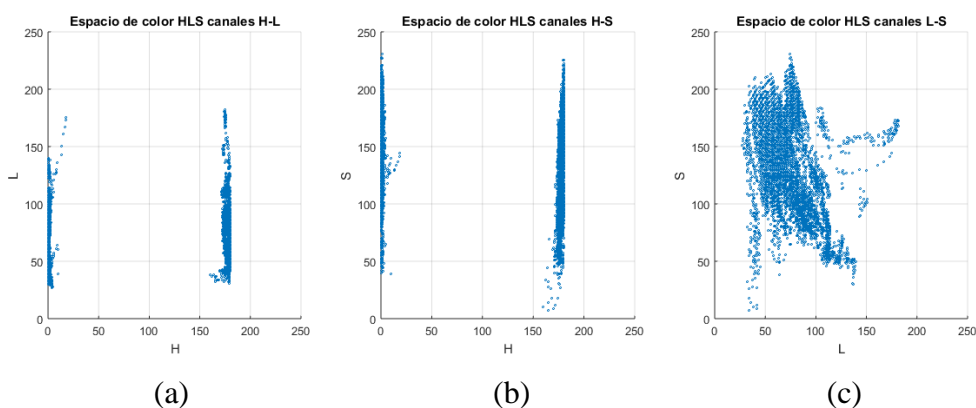


Figura 22. Distribución del color rojo en el espacio HSL, canales: (a) H-L, (b) H-S, (c) L-S.

La **Tabla 4**, muestra la variación de los valores para los canales de los espacios de color, en donde se puede observar que los espacio de color Lab y RGB normalizado son los que tienen una distribución más compacta. Para el espacio de color Lab y RGB normalizado los canales a-b y Rn-Gn respectivamente, son los que tienen una distribución más compacta. De esta manera, los espacios de color **Lab (canales a-b)** y **RGB normalizado (canales Gn-Bn)**. El siguiente paso consiste en realizar un estudio para determinar el espacio de color más robusto, y así determinar cuál de ellos se utiliza en la aplicación final.

Tabla 4.

Variación de los valores en los distintos canales de los diferentes espacios de color.

Espacio de color	RGB			YCrCb			Lab		
Canales	R	G	B	Y	Cr	Cb	L	a	b
Rango de variación	0-250	0-200	0-150	0-200	120-240	40-140	0-200	130-200	120-200
Variación	250	200	150	200	120	100	200	70	80

Espacio de color	RGB normalizado			HSL			HSV		
Canales	Rn	Gn	Bn	H	S	L	H	S	V
Rango de variación	70-230	20-90	0-90	0-170	0-200	0-250	0-180	0-250	0-250
Variación	160	70	90	170	200	250	180	250	250

La variación de los valores de los píxeles para el canal a y b del modelo de color Lab es de 70 y 80, respectivamente. Mientras tanto, el modelo de color RGB normalizado presenta una distribución más uniforme en los canales Gn y Bn, los píxeles en estos canales varía entre 20-90 y 0-90, respectivamente.

3.3 Generación de regiones de interés mediante $k - NN$ usando $K_m - means$

La segmentación está basada en el algoritmo de clasificación $k - NN$ (k- Nearest Neighbors), este es un algoritmo que almacena todos los casos disponibles (entrenamiento) y clasifica los nuevos casos sobre la base de una medida de similitud; por ejemplo, utiliza la medida de distancia para determinar la similitud de la nueva muestra para determinar a cual clase pertenece. Las medidas de distancia que utiliza son: Euclidea, Manhattan, Minkowski y Hamming (Duda, Hart, & Stork, 2001).

El parámetro k determina el número de vecinos más cercanos que debe cumplir la nueva muestra debe cumplir para ser clasificada como parte de una clase (Duda, Hart, & Stork, 2001). La **Figura 23 (a)** muestra un ejemplo de un clasificador $3NN$ en donde se puede diferenciar la clase de color rojo y clase de color azul, siendo G_n y B_n las características. El círculo verde representa la muestra a clasificar y dentro del

círculo de color negro se encuentran los 3 vecinos más cercanos; por votación el círculo de color verde pertenece a la clase de color rojo, ya que tiene 2 votos a favor y 1 voto a favor de la clase de color azul.

Para agrupar los datos utilizados por el clasificador se utiliza el algoritmo de agrupación $K_m - means$ (Duda, Hart, & Stork, 2001); de esta forma, se obtiene K_m centroides para las clases de interés (color rojo) y no interés (otros colores). La **Figura 23 (b)** muestra un ejemplo de aplicación del algoritmo de agrupación $K_m - means$, siendo B_n y G_n las características de las clases; en este ejemplo se utiliza un valor de K_m igual a 5, en donde se agrupa los datos en 5 grupos representados por los centroides $C1 - C5$ para su posterior análisis.

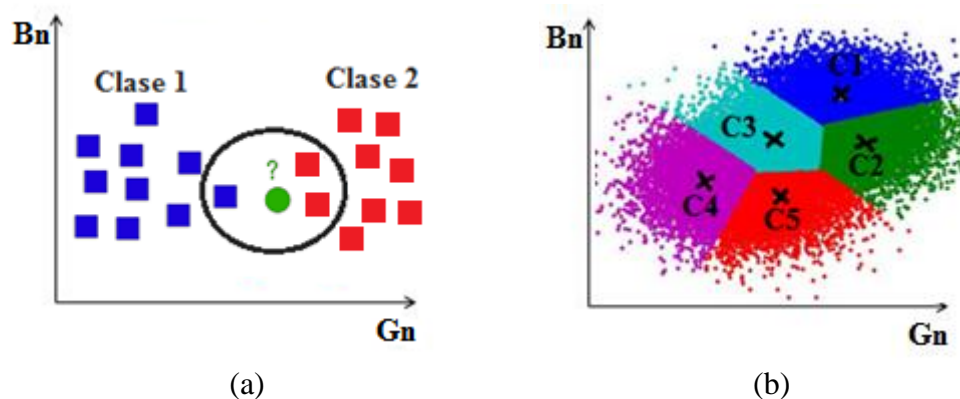


Figura 23. Ejemplos de algoritmos utilizados para la segmentación del color rojo: (a) algoritmo de clasificación $k - NN$, (b) algoritmo de agrupamiento de datos $K_m - means$.

Para la generación de las ROIs se realiza la segmentación basada en el color, para ello se usan dos clases, una de interés (color rojo) y otra clase de no interés asociada al resto de colores. En la **Figura 24**, se muestra la distribución de los colores rojo y no rojo en las componentes $G_n - B_n$ y $a - b$, que fueron las componentes con la mejor distribución de los espacios RGB normalizado y Lab, respectivamente. El color rojo representa la clase de interés y el color azul la clase de no interés.

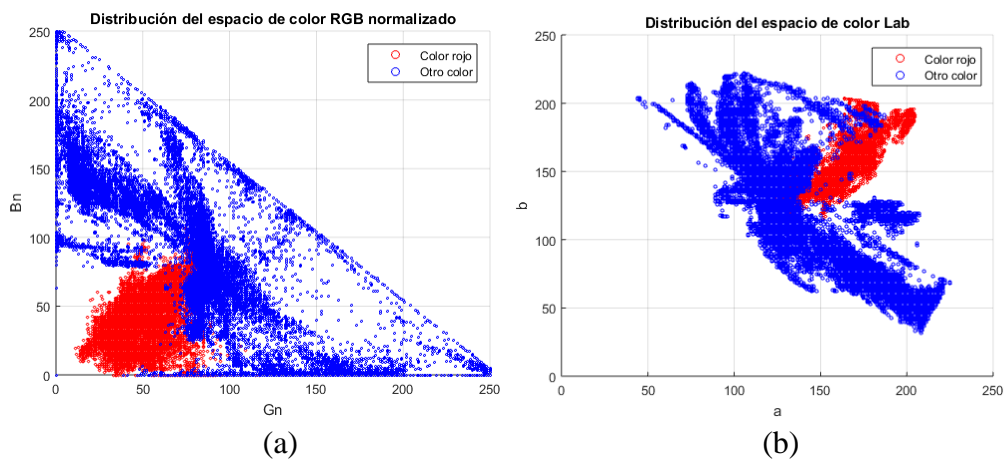


Figura 24. Distribución del color de interés y no interés del espacio en los espacios de color: (a) RGB normalizado, (b) Lab.

Existen diversos métodos para determinar el número óptimo de centroides K_m dependiendo de la distribución de los datos. En este proyecto se consideran los siguientes: Calinski-Harabasz (Caliński & Harabasz, 1974), Davies-Bouldin (Davies & Bouldin, 1979), Gap (Tibshirani, Walther, & Hastie, 2001), Silhouettes (Rousseeuw, 1987). Sin embargo, el valor final se escoge experimentalmente, ya que los métodos anteriores sugieren un buen punto de partida para determinar el valor final; a esta iniciativa se lo llama Método Experimental (ME).

Para evaluar el rendimiento del clasificador se realiza el análisis de la característica operativa del receptor (ROC, del inglés Receiver Operating Characteristics). La curva ROC se representa en el eje de las abscisas la tasa de falsos positivos, mientras que en el eje de la ordenada la tasa de verdaderos positivos. El área bajo la curva (AUC, del inglés area under the curve) de un clasificador corresponde a la probabilidad que tiene éste de realizar una clasificación para una muestra aleatoria, el valor está definido entre 0 y 1. Cuando el valor del AUC es igual a 1, significa que es un clasificador perfecto y para valores menores a 0.5 se considera como un mal clasificador (Fawcett, 2004).

El número de centroides para los modelos de color se muestran en la **Tabla 5** y **Tabla 6**, así como el número final de centroides determinado por el método experimental. Además se muestran los valores del AUC para cada uno de los casos, con este valor se elige el número de centroides a utilizar. Las curvas ROC se pueden

observar en la **Figura 25**, donde se muestra que el número de centroides determinados mediante el método experimental tienen un mejor rendimiento. Además, en la **Figura 26** y **Figura 27** se muestran los métodos aplicados para seleccionar el valor K_m del algoritmo $K_m - means$.

Tabla 5.

Estimación del número de centroides para el espacio de color RGB normalizado.

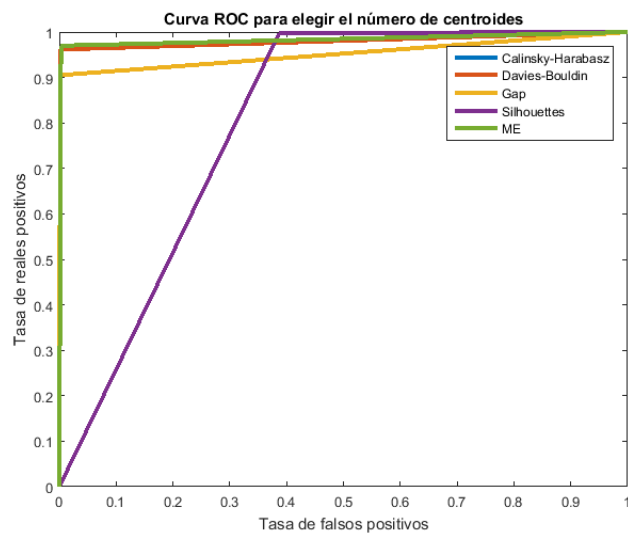
Espacio de color: RGB normalizado				
Método	Clase:	Clase:	AUC	Tiempo de cómputo
	color rojo	otro color		
	K_m	K_m		
Calinski-Harabasz	10	50	0.955	14.75 ms
Davies-Bouldin	20	40	0.975	14.89 ms
Gap	10	50	0.940	15.15 ms
Silhouette	20	10	0.790	11.23 ms
ME	30	40	0.984	16.38 ms

Tabla 6.

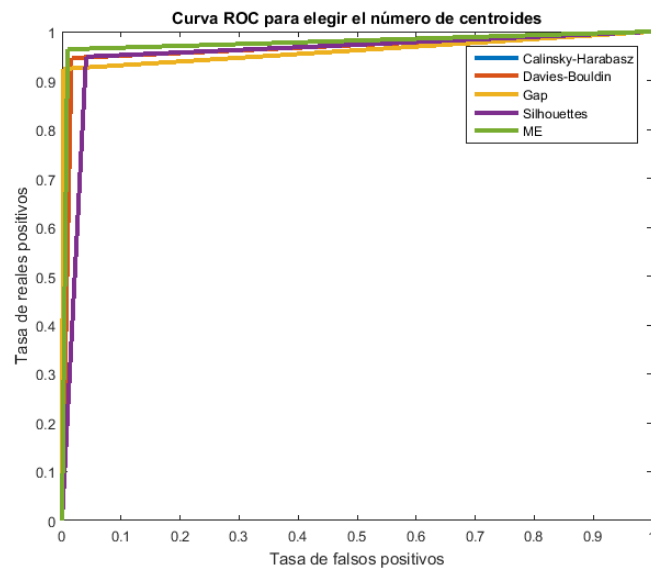
Estimación del número de centroides para el modelo de color Lab.

Espacio de color: Lab				
Método	Clase:	Clase:	AUC	Tiempo de cómputo
	color rojo	otro color		
	K_m	K_m		
Calinski-Harabasz	10	20	0.954	9.83 ms
Davies-Bouldin	10	40	0.965	12.27 ms
Gap	10	20	0.956	9.92 ms
Silhouette	10	20	0.953	9.97 ms
ME	20	40	0.977	15,12 ms

De acuerdo a la **Tabla 5** y **Tabla 6**, el espacio de color RGB normalizado y Lab, presentan valores del AUC de 0.984 y 0.977, con tiempos de cómputo de 16.38ms y 15.12ms respectivamente, debido a que los tiempos de ejecución no tienen mayor diferencia y el área de la curva ROC que más se acerca a 1 es la del espacio de color **RGB normalizado**, entonces se elige este espacio de color para la aplicación final.



(a)



(b)

Figura 25. Curvas ROC para determinar el número de centroides (K_m) en los espacios de color: (a) RGB normalizado, (b) Lab.


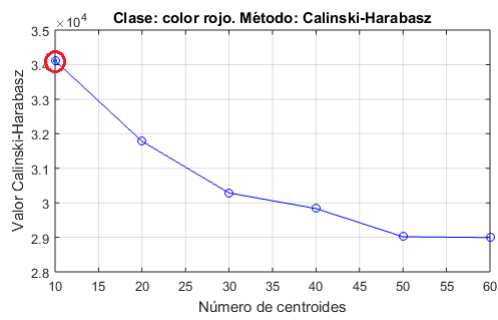




Figura 26. Métodos de elección del número K_m para el algoritmo $K_m - means$, para el espacio RGB normalizado: (a) y (b) Calinski-Harabasz, (c) y (d) Davies-Bouldin, (e) y (f) Gap (g) y (h) Silhouettes; para la clase de interés y no interés respectivamente.




(a)



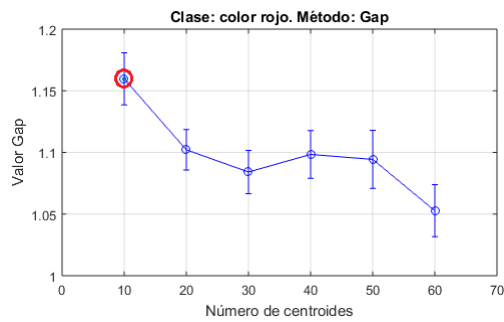
(b)




(c)




(d)




(e)



(f)



(g)



(h)

Figura 27. Métodos de elección del número K_m para el algoritmo $K_m - means$, para el espacio Lab: (a) y (b) Calinski-Harabasz, (c) y (d) Davies-Bouldin, (e) y (f) Gap, (g) y (h) Silhouettes; para la clase de interés y no interés respectivamente.

Con el número de centroides determinados, en la **Figura 28** se muestra el modelamiento (número de centroides) para los modelos de color RGB normalizado y Lab tanto para la clase de interés (color rojo), como para la de no interés (otros colores), estos centroides servirán de base para el entrenamiento del clasificador $k - NN$.




Figura 28. Distribución de los centroides de los espacios de color: (a) RGB normalizado, componentes Gn-Bn; (b) Lab, componentes a-b.

Para diseñar el clasificador $k - NN$, la elección del parámetro k depende entre otros factores del número de ejemplos utilizados (Duda, Hart, & Stork, 2001). Para determinar el valor óptimo de k se utilizan las curvas ROC (Fawcett, 2004) generadas para cada valor de k entre 1 y 8. La **Tabla 7** muestra el valor del AUC, y la **Figura 29** muestra las curvas ROC, en ambos casos generadas para cada valor de k .

De acuerdo a la **Tabla 7**, los valores de $k = 3$ y $k = 4$, ofrecen los mejores resultados, con valores para el AUC de 0.986 y 0.987, respectivamente. Para la elección final se utiliza los resultados de la **Figura 31** generada con $k = 3$, sobre el espacio RGB normalizado.

Tabla 7.

Elección del parámetro k para el algoritmo de clasificación $k - NN$.

k	AUC	Tiempo de computo
1	0.985	15.27 ms
2	0.931	15.82 ms
3	0.986	16.34 ms
4	0.987	16.41 ms
5	0.985	16.91 ms
6	0.983	17.80 ms
7	0.982	18.35 ms
8	0.983	19.38 ms




Figura 29. Curvas ROC para determinar el valor de k , para el algoritmo de clasificación $k - NN$, sobre el espacio de color RGB normalizado.

En la **Figura 31** se muestra la curva ROC generada para el algoritmo de clasificación con el valor de $k = 3$, $K_m = 30$ y 40 para la clase de color rojo y la clase de otros colores, respectivamente; aplicado sobre el espacio de color RGB normalizados, para estos parámetros se obtiene el área bajo la curva ROC de 0.986 con un tiempo de ejecución de 16.34 ms.




Figura 30. Segmentación de las señales Pare (superior) y Ceda el Paso (inferior) utilizando el algoritmo $k - NN$, en el espacio de color RGB normalizado: (a) Imagen original, (b) $k = 3$, (c) $k = 4$.




Figura 31. Curva ROC para el clasificador final $k - NN$ con el valor de $k = 3$, y con valores de K_m de 30 y 40 para la clase de interés y de no interés respectivamente.

3.4 Generación de ROIs y resultados parciales

El proceso de segmentación tiene varios inconvenientes a superar, entre los principales están:

- Existencia de regiones que no representen señales de tránsito, debido a que presentan colores iguales a las señales.
- Cuerpos que no se pueden dividir entre el fondo y la señal de interés.
- La velocidad del vehículo, que corrompe la calidad de la imagen.
- La distancia de la cámara a las señales, a mayor distancia mayor distorsión.

Para resolver estos inconvenientes, se utiliza los operadores morfológicos de dilatación y erosión (Pajares & de la Cruz, 2002), el primero para adicionar píxeles a los potenciales candidatos, y de esta manera mejorar las ROIs; y el segundo para eliminar pequeños cuerpos de la imagen. Para encontrar cuerpos en la imagen se utiliza el método de detección de bordes mediante la aplicación del operador Laplaciano (Pajares & de la Cruz, 2002) en la imagen. Además, se optó por eliminar los cuerpos que no cumplen con características específicas de tamaño para ser candidatos a señales de tránsito, las cuales se muestran en la **Tabla 8**. Estos valores se determinaron experimentalmente.

Tabla 8.

Características que debe cumplir una ROI en una imagen de tamaño 640x480.

Característica	Valor mínimo	Valor máximo
área	400 píxeles	10000 píxeles
relación (ancho/alto)	0.6	1.4
distancia	20 m	5 m

En la **Figura 32**, **Figura 33** y **Figura 34** se muestra el proceso de detección en tres escenarios: en días soleados, oscuros y normales. Adicionalmente, se muestra la aplicación de los procesos de dilatación, erosión, la eliminación de cuerpos que no se consideran como potenciales candidatos a señales de tránsito y las ROIs finales, las que son enviadas a la etapa de clasificación.




Figura 32. Resultados de la generación de ROIs de las señales Pare y Ceda el Paso para un día de iluminación normal: (a) imagen original, (b) aplicación del filtro de mediana, (c) imagen en el espacio RGB normalizado, (d) segmentación, (e) resultado de aplicar la erosión a (d), (f) resultado de aplicar la dilatación a (e), (g) eliminación de cuerpos que no cumplen con especificaciones de área y relación largo/ancho, (h) ROIs para la etapa de clasificación.




Figura 33. Resultados de la generación de ROIs de las señales Pare y Ceda el Paso para un día soleado: (a) imagen original, (b) aplicación del filtro de mediana, (c) imagen en el espacio de color RGB normalizado, (d) segmentación, (e) resultado de aplicar la erosión a (d), (f) resultado de aplicar la dilatación a (e), (g) eliminación de cuerpos que no cumplen con especificaciones de área y relación largo/ancho, (h) ROIs para la etapa de clasificación.

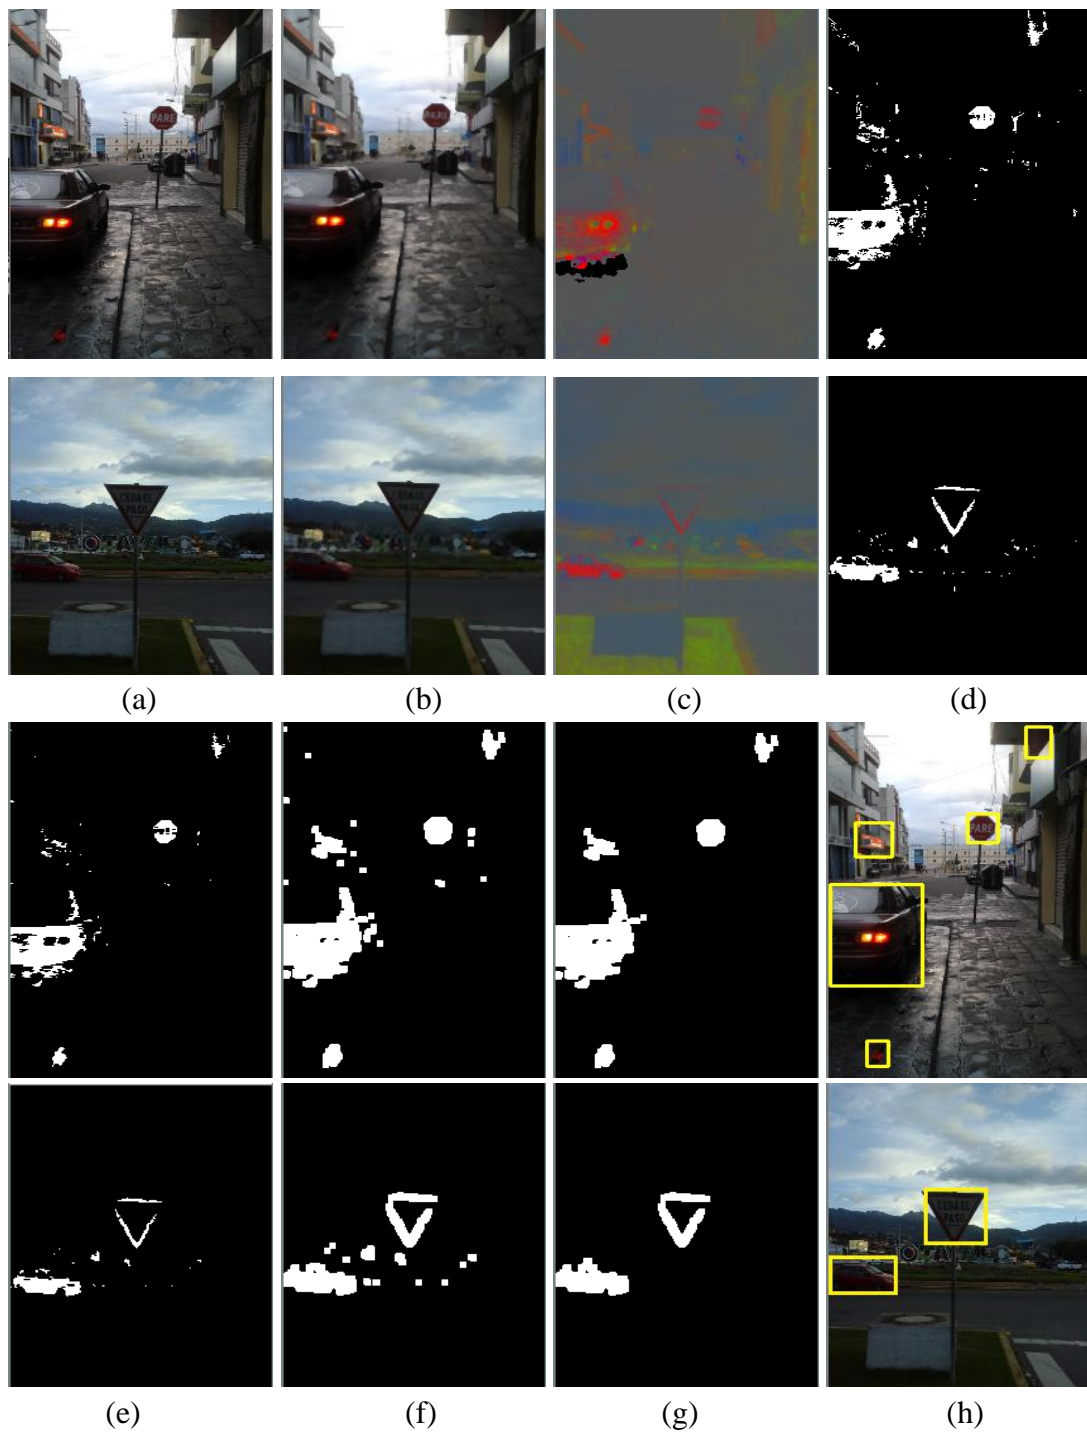


Figura 34. Resultados de la generación de ROIs de las señales Pare y Ceda el Paso para un día obscuro: (a) imagen original, (b) aplicación del filtro de mediana, (c) imagen aplicada el espacio de color RGB normalizado, (d) segmentación, (e) resultado de aplicar la erosión a (d), (f) resultado de aplicar la dilatación a (e), (g) eliminación de cuerpos que no cumplen con especificaciones de área y relación largo/ancho, (h) ROIs para la etapa de clasificación.

3.5 Conclusiones de la etapa de detección

En la primera parte de la etapa de detección se realiza un estudio del color mediante la aplicación de 6 espacios de color, los mejores resultados ante variaciones en la iluminación se obtienen con el espacio RGB normalizado. Para la segmentación se utilizó la clasificación por color para discriminar el color rojo del resto de colores. Para ello, se ha utilizado el algoritmo $K_m - means$ para agrupar los datos de entrenamiento y el clasificador $k - NN$. El número de centroides K_m fue de 30 y 40 para la clase interés (color rojo) y no interés (otros colores), respectivamente. Mientras que para el algoritmo de clasificación se utilizó $k = 3$, obteniendo en conjunto un valor del AUC de 0.986 con un tiempo de procesamiento promedio de 16.34 ms por imagen de tamaño de 640x480 píxeles.

CAPÍTULO IV

4. RECONOCIMIENTO DE SEÑALES DE TRÁNSITO DEL ECUADOR

4.1 Introducción

En el presente capítulo se realiza un análisis de todas las ROIs provenientes de la etapa de detección, para determinar si corresponden a una señal de Pare, Ceda el Paso u otro objeto, para lo cual esta etapa se divide en 3 partes: Pre-procesamiento de los candidatos, extracción de características y clasificación, las cuales se observan en la **Figura 35**.




Figura 35. Esquema propuesto para el reconocimiento de señales de tránsito.

- **Pre-procesamiento de los candidatos:** En esta parte se procede a normalizar a una misma escala todas las ROIs provenientes de la etapa de detección, posteriormente se transformará a escala de grises y se realizará una ecualización de histograma para obtener una imagen con una distribución uniforme para cada nivel de gris.
- **Extracción de Características:** En esta parte se obtiene las características más representativas de cada ROI utilizando descriptores de imágenes, en este caso se empleará la técnica de Histograma de Gradiente Orientado (HOG),

utilizada para obtener información acerca de la forma geométrica de los elementos de cada ROI.

- **Clasificación:** En esta parte se procede a determinar si la ROI es una señal de tránsito, y a qué tipo de señal pertenece, para lo cual se tiene las SVM como clasificador, para obtener las características óptimas de desempeño del clasificador se procede a realizar el entrenamiento con diferentes tipos de núcleos y características HOG, y posteriormente validar los resultados por medio de las curvas ROC.

4.2 Pre-Procesamiento de los Candidatos

La primera parte de la etapa de reconocimiento es obtener todas las ROIs que contengan un posible candidato a ser una señal de tránsito, en la **Figura 36** se observa la imagen procedente de la etapa de detección, para lo cual el primer paso es separar las ROIs en imágenes independientes, las cuales se transformaran a escala de grises para reducir las componentes de color a un solo canal como se observa en la **Figura 37**.




Figura 36. Resultados de la etapa de detección: (a) imagen original identificada las ROIs, (b) ROIs en imágenes independientes.



Figura 37. Transformación a escala de grises en señales de Ceda el Paso (izquierda) y Pare (derecha): (a) imágenes originales, (b) imágenes en escala de grises.

Las ROIs provenientes de la etapa de detección no tienen un tamaño definido debido a que dependen de la distancia de la cámara y del área que ocupan en la imagen, para lo cual, el primer paso es establecer un tamaño estándar para todas las imágenes, en este caso se ha seleccionado el tamaño de 32x32 píxeles, los resultados obtenidos en el escalamiento se observa en la **Figura 38**.




Figura 38. Escalamiento de imágenes: (a) imágenes originales, (b) imágenes escaladas a 32x32 píxeles.




Figura 39. Ecualización de histograma en señales de Ceda el paso (arriba) y Pare (abajo): (a) imágenes originales, (b) histogramas de imágenes originales, (c) imágenes ecualizadas, (d) histogramas de imágenes ecualizadas.

Debido a las diferentes condiciones ambientales, la ubicación de la cámara, y otros factores externos, las ROIs presentan variación de iluminación, para lo cual se ha aplicado la técnica de “Ecuilización de Histograma”, que nos permite la distribución uniforme de los niveles de gris de las imágenes y así poder aumentar el contraste de la imagen y distinguir mejor los objetos que forman parte de la misma (González Marcos, y otros, 2006), los resultados de la ecualización de histograma en una imagen se observa en la **Figura 39**, en los cuales se observa que en la imagen original los niveles de gris tienden hacia los niveles oscuros en el caso de la señal de Ceda el Paso y en el caso de la señal de Pare los niveles de gris tienden hacia los colores claros, aplicando la ecualización de histograma la distribución de los niveles de gris es uniforme y visualmente se logra resaltar al objeto de interés para los casos de las señales de Ceda el Paso y Pare.

4.3 Extracción de características usando HOG

Una vez obtenido todas las imágenes que contienen una ROI con la misma escala y con un buen contraste en sus niveles de gris, el siguiente paso es obtener las características representativas de las imágenes que pueden contener una señal de tránsito, para lo cual se utiliza el “Histograma de Gradiente Orientado” o comúnmente conocidos como HOG, la utilización de HOG se debe a que sus características son invariantes a la escala, normalización de contraste local y la utilización de los gradientes ponderados que proveen información acerca de la forma del objeto a reconocer. (Zaklouta & Stanculescu, Real-time traffic sign recognition in three stages, 2014).

El método de HOG fue propuesto por (Dalal & Triggs, 2005) y originalmente fue utilizado para la detección de peatones, pero debido a sus excelentes resultados se ha expandido a otros campos del reconocimiento de objetos. Para el cálculo del descriptor se divide a la imagen en celdas y se agrupan las celdas en bloques como se ilustra en la **Figura 40**. Para su construcción se siguen los siguientes pasos:

- Cálculo del gradiente de la imagen
- Construcción del histograma de orientación

- Normalización de los histogramas de orientación
- Construcción de las características HOG




Figura 40. Estructura de características HOG (Dalal & Triggs, 2005).

4.3.1 Cálculo del gradiente de la imagen

Los bordes de una imagen se definen como la frontera de separación entre dos regiones de una imagen con intensidades en los niveles de grises significativamente diferentes (Pajares & de la Cruz, 2002), para lo cual se utiliza el cálculo del gradiente de imágenes para determinar las variaciones de nivel de gris, se ha utilizado dos filtros diferenciales como se muestra en la ecuación (3), realizando la convolución entre la imagen y los filtros, para obtener las componentes horizontales G_H y las componentes verticales G_V de la gradiente (Bertozzi, y otros, 2007), los resultados obtenidos al aplicar los filtros derivativos se observan en la **Figura 41**.

$$F_{G_H} = [-1 \quad 0 \quad 1] \quad F_{G_V} = \begin{bmatrix} -1 \\ 0 \\ 1 \end{bmatrix} \quad (3)$$

Obteniendo las componentes G_H y G_V del gradiente, se realiza la construcción del módulo M_G y la orientación O_G del gradiente en cada píxel de la imagen por medio de la ecuación (4) (Bertozzi, y otros, 2007), los resultados obtenidos se observa en la **Figura 42**, con lo cual se tiene la información necesaria acerca de la intensidad de nivel de gris y la dirección de los bordes del objeto que representa una señal de tránsito.

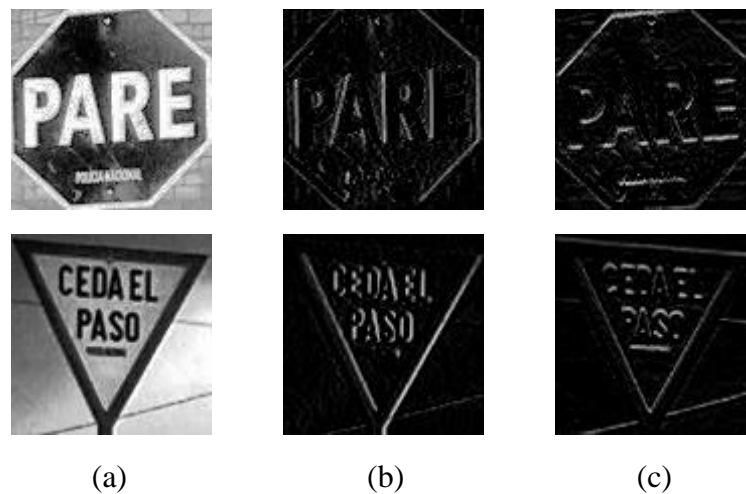


Figura 41. Aplicación filtros diferenciales en señales de Pare (arriba) y Ceda el Paso (abajo): (a) imágenes originales, (b) imágenes de componentes verticales del gradiente G_V , (c) imágenes de componentes horizontales del gradiente G_H .




Figura 42. Cálculo del gradiente en señales de Pare (arriba) y Ceda el Paso (abajo): (a) imágenes originales, (b) imágenes del módulo del gradiente M_G , (c) imágenes de la orientación del gradiente O_G .

$$M_G = \sqrt{G_H^2 + G_V^2} ; \quad O_G = \tan^{-1} \left(\frac{G_H}{G_V} \right) \quad (4)$$

4.3.2 Construcción del histograma de orientación

La construcción del histograma de orientación se lo realiza en pequeñas regiones de la imagen denominadas “Celdas” (Dalal & Triggs, 2005), la división de la imagen en celdas se observa en la **Figura 43**, para lo cual se realiza el cálculo del gradiente en cada celda de la imagen, y se obtiene el módulo y la dirección del gradiente que representa el borde del objeto, la dirección del gradiente posee un rango de orientaciones de $[-90^\circ; 90^\circ]$ ó $[-\frac{\pi}{2}; \frac{\pi}{2}]$ (Zaklouta & Stanculescu, Real-time traffic sign recognition in three stages, 2014).



Figura 43. División de una imagen en 25 celdas; 5 celdas verticales y 5 celdas horizontales.

El histograma de orientaciones representa la ponderación de dirección que posee cada celda en la imagen, se lo construye de la siguiente forma:

- Dividir el rango de orientaciones en n intervalos fijos como se muestra en la **Figura 44** (a).
- Analizar la orientación de gradiente O_G que posee cada píxel y calcular la ponderación w_k para cada intervalo de orientación k utilizando la ecuación (5).
- Sumar los módulos del gradiente M_G de los píxeles que pertenecen a cada intervalo k , para encontrar las ponderaciones de cada orientación $h(k)$, utilizando la ecuación (5).

- Formar el histograma de orientación para cada intervalo k , utilizando las ponderaciones de intensidad de cada orientación $h(k)$, como se muestra en **Figura 44** (b).

$$w_k = \begin{cases} 1; & \text{Si } O_G \in \text{intervalo } k \\ 0; & \text{Caso contrario} \end{cases}$$

$$h(k) = \sum w_k M_G \quad (5)$$

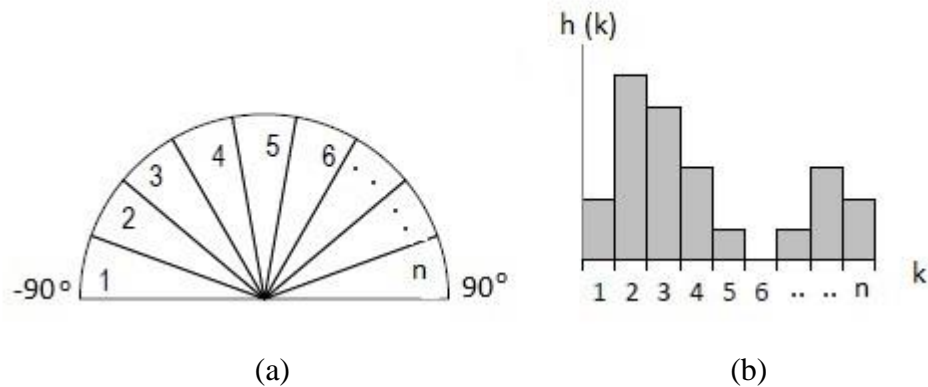


Figura 44. Construcción de histograma de orientación: (a) intervalos de orientación, (b) histograma de orientación.

Luego, se construye el histograma de orientación para todas las celdas en las que se ha dividido la imagen, el tamaño de la celda está dado en píxeles, el tamaño de la celda puede tomar valores de $t_{celda} = 2, 4, 8$ y 16 píxeles por lado, dando un total de $256, 64, 16$ y 4 celdas por imagen respectivamente, esto se observa en la **Figura 45** y el intervalo de orientaciones puede tomar valores de $n = 3, 6, 9, 12$ y 15 intervalos, esto se observa en la **Figura 46**. Los histogramas de orientaciones en imágenes se lo observa en la **Figura 47**, en la que se indica el caso donde tamaño de celda es de 16×16 píxeles y con 9 intervalos de orientación.




Figura 45. Tamaños de celdas a utilizar: (a) 2x2 píxeles, (b) 4x4 píxeles, (c) 8x8 píxeles, (d) 16x16 píxeles.

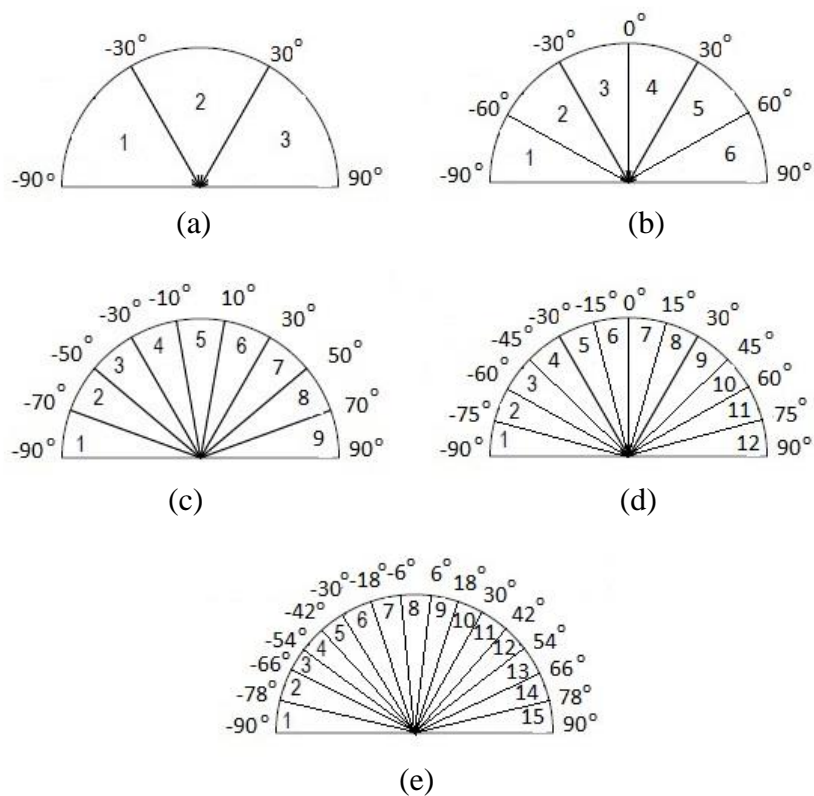


Figura 46. Intervalos de orientación del gradiente a utilizar: (a) 3 intervalos, (b) 6 intervalos, (c) 9 intervalos, (d) 12 intervalos, (e) 15 intervalos.




Figura 47. Cálculo de histograma de gradientes orientados en señales de ceda el paso (arriba) y pare (abajo): (a) imágenes originales divididas en 4 celdas, (b) histograma de gradientes orientados por celda con 9 orientaciones.

4.3.3 Normalización de los histogramas de orientación

Existen histogramas de orientación obtenidos de imágenes que contienen un mismo objeto pero que poseen diferentes ponderaciones de intensidad debido a las variaciones de contraste entre las imágenes, producidos por los cambios de iluminación, para contrarrestar esas variaciones se emplea el método de normalización, el cual consiste en la agrupación de celdas adyacentes en un solo conjunto denominado “Bloque” (Tomasi, 2015), para cada bloque se obtiene el histograma de gradiente orientado de cada celda, luego se concatenan todos los histogramas uno a continuación del otro obteniendo un vector v , y se realiza la normalización de ese vector utilizando la ecuación (6), obteniendo un vector normalizado como se muestra en la **Figura 48**.

$$v = (x_1, x_2, \dots, x_n)$$

$$v' = \frac{v}{\sqrt{\|v\|^2 + \varepsilon}} \quad (6)$$




Figura 48. Normalización de histograma: (a) obtención de bloque, (b) histogramas de las celdas del bloque, (c) concatenación de histogramas, (d) histograma normalizado.

4.3.4 Construcción de las características HOG

El vector de características HOG que representa a la imagen se compone de la concatenación de histogramas normalizados, los cuales se obtienen desplazando el bloque por toda la imagen, el desplazamiento del bloque permite el solapamiento de celdas, haciendo que la celda pueda pertenecer a varios bloques y haciendo que ésta tenga una normalización diferente para cada bloque, esto permitirá obtener una

eliminación de la variación de contraste de forma local para cada celda, la construcción de las características HOG se observa en la **Figura 49**.




Figura 49. Construcción de las características HOG: (a) desplazamiento del bloque en la imagen, (b) concatenación de los histogramas para obtener un vector de 324 elementos.

El tamaño del vector de características HOG, viene determinado por la ecuación (7), donde n_{HOG} es el tamaño del vector, $n_{bloques}$ es el número de bloques que componen la imagen, $n_{celdas/bloque}$ es el número de celdas que contiene cada bloque y $n_{orientaciones}$ es el intervalo de orientaciones del gradiente, en la **Tabla 9** se observa todas las dimensiones que toma el vector HOG para imágenes de 32x32 píxeles, con un bloque de 2x2 celdas, los cuales serán utilizados para en entrenamiento del algoritmo de clasificación. En la **Figura 50** se observan los resultados obtenidos para imágenes de 32x32 píxeles, celdas de 8x8 píxeles, bloques de 2x2 celdas y 9 orientaciones.

$$n_{HOG} = n_{bloques} * n_{celdas/bloque} * n_{orientaciones} \quad (7)$$

$$n_{bloques} = n_{celdas} - n_{celdas/bloque} + 1$$

Tabla 9.

Tamaño del vector de características HOG para diferentes orientaciones y tamaño de celda.

Orientaciones	Tamaño de celda en píxeles			
	2x2	4x4	8x8	16x16
3	2700	588	108	12
6	5400	1176	216	24
9	8100	1764	324	36
12	10800	2352	432	48
15	13500	2940	540	60

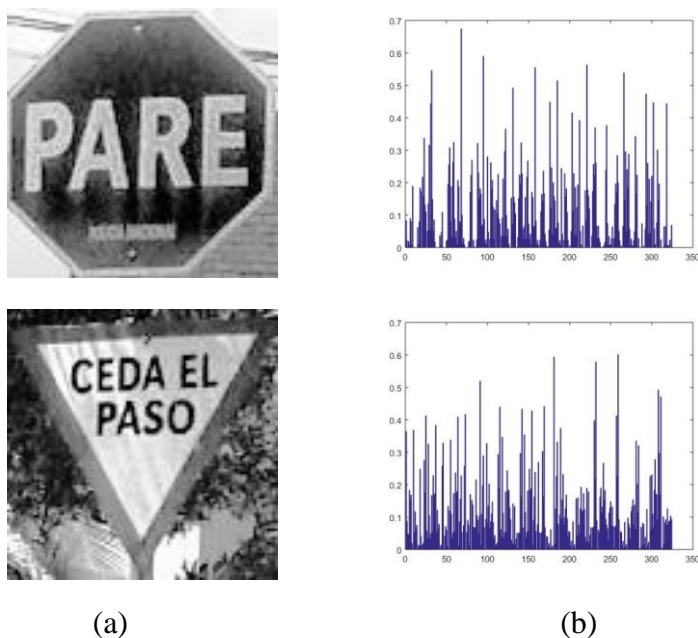


Figura 50. Características HOG en señales de Pare (arriba) y Ceda el Paso (abajo): (a) imágenes originales, (b) características HOG con celdas de 8x8 píxeles, bloques de 2x2 celdas y 9 orientaciones.

4.4 Clasificación usando SVM

La clasificación se realiza por medio de Support Vector Machine comúnmente denominada como SVM, el cual es un clasificador binario y se basa en encontrar un hiperplano óptimo como función de decisión entre varios conjuntos de datos (Suard,

Rakotomamonjy, Bensrhair, & Broggi, 2006), en este caso se cuenta con 3 conjuntos de datos los cuales son las señales de Pare, Ceda el Paso y otros elementos que no pertenezcan a las anteriores señales, para obtener los parámetros óptimos que determinen la función de decisión óptima de clasificación se realiza el entrenamiento y validación de los clasificadores.

4.4.1 Entrenamiento y validación del clasificador

El sistema de reconocimiento se basa en la técnica de aprendizaje supervisado, para lo cual se dispone de una base de datos con imágenes obtenidas en calles de distintas ciudades del Ecuador, las imágenes contienen señales de Pare y Ceda el Paso, las cuales se obtuvieron a diferentes distancias, diferentes condiciones de iluminación y de rotación. El número de imágenes disponibles en la base de datos se describen en la **Tabla 10** (Li, Sun, Liu, & Wang, 2015), la imágenes utilizadas para construir la base de datos se observa en la **Figura 51**.

Tabla 10.

Base de datos con imágenes disponibles para el entrenamiento del clasificador

	Señales de Pare	Señales de Ceda el Paso	Muestras Negativas	Total
Número de Imágenes	1000	1000	4000	6000

El conjunto de datos disponibles para el entrenamiento y la validación se lo determina por medio del “método de retención” o comumente denominado “Holdout”, que es una técnica de validación de clasificadores, que consiste en separar la base de datos en dos subconjuntos mutuamente excluyentes denominados “conjunto de entrenamiento” y “conjunto de prueba”, comumente la relación de muestras de los conjuntos es de 3 a 1, las muestras que pertenecen a cada conjunto se determinan de forma aleatoria (Kohavi, 1995), los datos de los conjuntos de entrenamiento y de prueba se observa en la **Tabla 11**.



(a)



(b)



(c)

Figura 51. Base de datos disponible: (a) muestras con señales de Ceda el Paso, (b) muestras con señales de Pare, (c) muestras negativas

Tabla 11.

Conjunto de entrenamiento y validación del clasificador

	Señales de Pare	Señales de Ceda el Paso	Muestras Negativas	Total
Conjunto de Entrenamiento	700	700	2800	4200
Conjunto de Prueba	300	300	1200	1800
				6000

El entrenamiento del clasificador comienza seleccionando las imágenes del conjunto de entrenamiento para pre-procesarlas y obtener las características HOG de cada una de las imágenes, para lo cual el conjunto de entrenamiento viene dado por el par (x_i, y_i) , donde $x_i \in R^n$ que representan las características HOG con un tamaño del vector n , $y_i \in \{1, 2, -1\}^l$ que representan a la señal de ceda el paso, señal de pare, y muestras negativas respectivamente, $i = 1, 2, 3, \dots, l$ dónde l es el tamaño del conjunto de entrenamiento. El entrenamiento trata de resolver el problema de optimización de la ecuación (8), encontrando los valores óptimos del hiperplano w y su parámetro b (Hsu, Chang, & Lin, 2003).

$$\min_{w, b, \varepsilon} \quad \frac{1}{2} w^T w + C \sum_{i=1}^l \varepsilon_i$$

$$\text{sujeto a: } \quad y_i(w^T \phi(x_i) + b) \geq 1 - \varepsilon_i \quad (8)$$

$$\varepsilon_i \geq 0$$

Los vectores de entrenamiento x_i son representados en el espacio n -dimensional por medio de la función de mapeo ϕ , para obtener una función de decisión mas generalizada y evitar el sobreajuste se tiene el factor de holgura ε_i , el valor C representa la penalización del error, mientras más grande sea el valor de C menor será el error, en el caso de que los datos de entrenamiento no sean separables linealmente se utiliza el método del “Kernel” o también denominado método del “Núcleo”, la funciones de núcleo a utilizar en este trabajo se muestran en la ecuación (9), donde γ , r y d son parámetros de la función de núcleo.

$$\text{Núcleo lineal: } K(x_i, x_j) = x_i^T x_j$$

$$\text{Núcleo Polinómico: } K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0 \quad (9)$$

$$\text{Núcleo Gaussiano (RBF): } K(x_i, x_j) = e^{-\gamma \|x_i - x_j\|^2}, \gamma > 0$$

La validación del clasificador para determinar cuál es el clasificador más óptimo se lo realiza con las imágenes del conjunto de prueba, pre-procesándolas y obteniendo su vector de características HOG, se realiza pruebas con los clasificadores entrenados con las diferentes funciones de núcleo de la ecuación (9), y para las diferentes características HOG de la **Tabla 9**, para determinar el clasificador más óptimo se obtienen las curvas ROC de todos los clasificadores utilizados y se escoge el que genera mejores resultados.

4.5 Resultados experimentales

Los resultados parciales obtenidos de la etapa de reconocimiento se basan en la obtención del clasificador más óptimo, para poder utilizarlo en el sistema automático de detección y reconocimiento de señales de tránsito, para ello se han entrenado varios clasificadores que dependen de la características HOG de las imágenes a utilizar, para lo cual se han establecido un tamaño fijo de imagen de 32x32, y bloques fijos de 2x2 celdas con solapación simple, se han variado el tamaño de celda, y el número de orientaciones de los histogramas, y para el clasificador SVM se han utilizado diferentes tipos de núcleos vistos en la ecuación (9), los parámetros de núcleos que proporcionan los mejores resultados fueron obtenidos experimentalmente y son: $C = 2^{15}$, $r = 0$, $d = 3$ y $\gamma = 1/k$ donde k es el tamaño del vector HOG mostrados en la **Tabla 9** (Hsu, Chang, & Lin, 2003).

Para determinar el clasificador más óptimo se ha utilizado un total de 60 clasificadores, los cuales se obtuvieron realizando la combinación entre las diferentes características HOG y SVM, para lo cual el tamaño de celdas escogidos son de 2x2, 4x4, 8x8, y 16x16 píxeles y con número de orientaciones de 3, 6, 9, 12 y 15, los resultados obtenidos se observan en las **Figura 52-Figura 53** en las cuales se observan las curvas ROC utilizadas para medir el desempeño de los clasificadores, en la **Tabla 12 - Tabla 15**, se observa numéricamente el desempeño de cada clasificador por medio del área bajo la curva de cada ROC (AUC) y el tiempo que emplea la etapa de reconocimiento para cada ROI.




Figura 52. Curvas ROC para clasificadores con características HOG con celdas de 2x2 píxeles (izquierda) y 4x4 píxeles (derecha): (a) Núcleo Lineal, (b) Núcleo Polinómico, (b) Núcleo Gaussiano.




Figura 53. Curvas ROC para clasificadores con características HOG con celdas de 8x8 píxeles (izquierda) y 16x16 píxeles (derecha): (a) Núcleo Lineal, (b) Núcleo Polinómico, (b) Núcleo Gaussiano.

Tabla 12.

Resultados de clasificación para clasificadores con características HOG con celdas de 2x2 píxeles.

Orientaciones	Tipo de núcleo					
	Lineal		Polinómico		Gaussiano	
	AUC	Tiempo	AUC	Tiempo	AUC	Tiempo
3	0.9899	7.27 ms	0.9805	21.69 ms	0.9863	9.09 ms
6	0.9899	17.21 ms	0.9689	62.61 ms	0.9949	20.62 ms
9	0.9913	28.29 ms	0.9812	112.97 ms	0.9935	33.98 ms
12	0.9942	43.36 ms	0.9769	176.26 ms	0.9899	52.22 ms
15	0.9927	58.53 ms	0.9761	234.47 ms	0.9920	70.32 ms

Tabla 13.

Resultados de clasificación para clasificadores con características HOG con celdas de 4x4 píxeles.

Orientaciones	Tipo de núcleo					
	Lineal		Polinómico		Gaussiano	
	AUC	Tiempo	AUC	Tiempo	AUC	Tiempo
3	0.9877	0.94 ms	0.9906	2.22 ms	0.9862	1.25 ms
6	0.9891	2.21 ms	0.9935	5.82 ms	0.9956	2.62 ms
9	0.9949	3.61 ms	0.9957	10.33 ms	0.9942	4.38 ms
12	0.9957	5.24 ms	0.9942	17.49 ms	0.9935	6.25 ms
15	0.9913	7.24 ms	0.9913	28.44 ms	0.9913	8.58 ms

Tabla 14.

Resultados de clasificación para clasificadores con características HOG con celdas de 8x8 píxeles.

Orientaciones	Tipo de núcleo					
	Lineal		Polinómico		Gaussiano	
	AUC	Tiempo	AUC	Tiempo	AUC	Tiempo
3	0.9603	0.25 ms	0.9913	0.35 ms	0.9755	0.33 ms
6	0.9784	0.37 ms	0.9947	0.64 ms	0.9834	0.44 ms
9	0.9798	0.54 ms	0.9949	1.04 ms	0.9784	0.63 ms
12	0.9762	0.73 ms	0.9921	1.79 ms	0.9827	0.86 ms
15	0.9834	0.96 ms	0.9971	2.76 ms	0.9819	1.11 ms

Tabla 15.

Resultados de clasificación para clasificadores con características HOG con celdas de 16x16 píxeles.

Orientaciones	Tipo de núcleo					
	Lineal		Polinómico		Gaussiano	
	AUC	Tiempo	AUC	Tiempo	AUC	Tiempo
3	0.9055	0.21 ms	0.9350	0.20 ms	0.9163	0.20 ms
6	0.9372	0.24 ms	0.9603	0.27 ms	0.9567	0.25 ms
9	0.9358	0.28 ms	0.9625	0.34 ms	0.9553	0.30 ms
12	0.9423	0.35 ms	0.9610	0.46 ms	0.9610	0.37 ms
15	0.9401	0.38 ms	0.9560	0.60 ms	0.9545	0.43 ms

4.6 Conclusiones de la etapa de reconocimiento

Observando las **Tabla 12 - Tabla 15** y las **Figura 52-Figura 53**, se determina que los clasificadores que poseen características HOG con tamaño de celda de 2x2 píxeles poseen un buen desempeño, pero a un costo computacional muy alto, debido a que el tamaño del vector HOG es muy grande, los clasificadores con características HOG con tamaño de celda de 16x16, son los que tuvieron el peor desempeño, debido a un vector HOG muy pequeño, y que no es suficiente para representar las características típicas de una señal de tránsito.

Los clasificadores que obtuvieron mejores resultados son los que poseen un tamaño de celda de 4x4 píxeles y 8x8 píxeles, siendo estos últimos los que requieren un costo computacional más bajo, por lo tanto el que mejor resultado obtuvo fue el clasificador que posee un tamaño de celda de 8x8 píxeles, bloques de 2x2 celdas con solapación simple, 9 orientaciones, y núcleo polinómico, para lo cual esas serán las características de HOG y el clasificador SVM que se utilizaran en el sistema automático de detección y reconocimiento de señales de tránsito en intersecciones viales.

CAPÍTULO V

5. PRUEBAS Y RESULTADOS

5.1 Introducción

En este capítulo se procede a implementar un sistema de adquisición y procesamiento de imágenes que funciona en tiempo real para validar los algoritmos de detección y reconocimiento. La etapa de experimentación consiste de varias pruebas con distintas condiciones meteorológicas y de iluminación, con lo cual se obtendrá los resultados finales de funcionamiento del sistema automático de detección y reconocimiento de señales de tránsito en intersecciones viales.

5.2 Sistema de percepción, procedimiento y visualización

- Percepción: es el encargado de obtener información visual acerca del entorno, este sistema consta de una cámara web USB 3.0, marca DFK AFU130-L53, de 12.8 MP.
- Procedimiento: el sistema de procesamiento en donde se implementan los algoritmos de detección y reconocimiento de señales de tránsito, este sistema consta de una tarjeta de desarrollo para sistemas embebidos Jetson TX1, de la marca NVIDIA.
- Visualización: es en donde se observan los resultados de la clasificación, para ello se utiliza un monitor MOT-YT07P a color de 7 pulgadas.

El sistema en general se lo observa en la **Figura 54**, el cual consta de una cámara web, la tarjeta de desarrollo Jetson TX1, y un monitor.




Figura 54. Sistema de percepción, procesamiento y visualización utilizada en el proyecto.

En la **Figura 55** se muestra el sistema de percepción, procesamiento y visualización instalado en un vehículo, para la realización de las pruebas de funcionamiento en tiempo real. En donde **1** representa el sistema de percepción, **2** el sistema de visualización y **3** el sistema de procesamiento.



Figura 55. Instalación del sistema de percepción, visualización y procesamiento en un vehículo.

5.3 Pruebas de funcionamiento

Las pruebas de funcionamiento del sistema automático de detección y reconocimiento de señales de tránsito se realizaron en las calles de las ciudades de Quito y Sangolquí, en diferentes días y en variadas condiciones climáticas y de iluminación. En la **Tabla 16** se muestra la información de las secuencias de video utilizadas para validar el sistema, a la vez en las **Figura 56-Figura 58** se muestran varios ejemplos del funcionamiento en los casos de días soleados, normales y nublados.



Figura 56. Pruebas de funcionamiento en condiciones iluminación soleado para señales de pare (izquierda) y ceda el paso (derecha): (a) imagen original, (b) generación de las regiones de interés, (c) respuesta del sistema.



(a)



(b)



(c)

Figura 57. Pruebas de funcionamiento en condiciones iluminación normal para señales de pare (izquierda) y ceda el paso (derecha): (a) imagen original, (b) generación de las regiones de interés, (c) respuesta del sistema.



(a)



(b)



(c)

Figura 58. Pruebas de funcionamiento en condiciones iluminación nublado para señales de pare (izquierda) y ceda el paso (derecha): (a) imagen original, (b) generación de las regiones de interés, (c) respuesta del sistema.

Tabla 16.

Secuencias de video utilizados para las pruebas de funcionamiento

	Condiciones de iluminación			Total
	Soleado	Normal	Nublado	
Tiempo de prueba	11:09 min.	16:32 min.	14:06 min	41:47 min
Número de imágenes	9999	14744	12442	37185

Además se analizó el comportamiento del sistema ante la complejidad de las escenas como son los casos con muchos objetos parecidos a una señal de tránsito y objetos con predominancia del color rojo. También se revisó el caso donde los obstáculos pueden ocluir parcial o totalmente a la señal y el deterioro de las señales de tránsito. Ejemplos de estos casos se observan en la **Figura 59-Figura 61**.



(a)



(b)




(c)


Figura 59. Pruebas de funcionamiento en escenarios complejos para señales de pare (izquierda) y ceda el paso (derecha): (a) imagen original, (b) generación de las regiones de interés, (c) resultado del sistema.



(a)



(b)



(c)


Figura 60. Pruebas de funcionamiento con oclusiones parciales para señales de pare (izquierda) y ceda el paso (derecha): (a) imagen original, (b) generación de las regiones de interés, (c) resultado del sistema.



(a)



(b)



(c)

Figura 61. Pruebas de funcionamiento con deterioro para señales de pare (izquierda) y ceda el paso (derecha): (a) imagen original, (b) generación de las regiones de interés, (c) resultado del sistema.

5.4 Resultados experimentales y análisis

Para el análisis de resultados se utilizan los siguientes conceptos, que son ilustrados en la **Figura 62**:

- **Reales positivos (RP):** Existe una señal de tránsito y el sistema reconoce la señal de tránsito.

- **Falsos negativos (FN):** Existe una señal de tránsito pero el sistema no reconoce ni una señal de tránsito.
- **Falsos positivos (FP):** No existe una señal de tránsito pero el sistema reconoce una señal de tránsito.
- **Reales negativos (RN):** No existe una señal de tránsito y el sistema no reconoce ni una señal de tránsito.



Figura 62. Respuestas del sistema: (a) real positivo, (b) falso negativo, (c) falso positivo, (d) real negativo.

El término “Ground Truth” o también denominado “Posición Verdadera” representa la detección ideal y generalmente es impuesta por el ser humano (Schimid, Mohr, & Bauckhage, 2000). Para realizar una correcta detección se debe tener en cuenta que los objetos determinados como reales positivos deben cumplir con la ecuación (10), donde el área de detección final (A_D) debe ser mayor a un umbral de área (U_A), V_{dt} representa la ventana detectada y V_{pv} representa la ventana de la posición verdadera, si A_D cumple con todo lo anterior, la detección es considerada un real

positivo, caso contrario es considerada como un falso positivo, en la **Figura 63** se observan todos los posibles casos que existen en la detección.

$$A_D = \frac{A_{(v_{dt} \cap v_{pv})}}{A_{(v_{dt} \cup v_{pv})}} > U_A \quad (10)$$

$$U_A = 0.5$$




Figura 63. Tipos de detección: (a) ventana de la posición verdadera, (b) detección con $A_D = 1$, (c) detección con $A_D > 0.5$, (d) múltiple detección con $A_D > 0.5$, (e) detección con $A_D < 0.5$, (f) detección con $A_D = 0$

Una medida del rendimiento del sistema se realiza por medio de las curvas DET (Deteccion Error Tradeoff) (Martin, Doddington, Kamm, Ordowski, & Przbocki, 1997), las cuales se construyen por medio de la ecuaciones (11)-(16), para lo cual es necesario obtener la matriz de confusión del sistema, que representa numéricamente los parámetros mostrados en la **Figura 62**, obtenidas para las diferentes condiciones

de iluminación de las pruebas de funcionamiento se muestran en las **Tabla 17-Tabla 19**, y la matriz de confusión del funcionamiento del sistema total se muestra en la **Tabla 20**.

Tabla 17.

Matriz de confusión para días normales.

Días normales		Resultado del clasificador	
		Positivo	Negativo
Instancia	Positivo	1034	152
Real	Negativo	42	13516

Tabla 18.

Matriz de confusión para días soleados.

Días soleados		Resultado del clasificador	
		Positivo	Negativo
Instancia	Positivo	403	159
Real	Negativo	42	9395

Tabla 19.

Matriz de confusión para días nublados.

Días nublados		Resultado del clasificador	
		Positivo	Negativo
Instancia	Positivo	1216	316
Real	Negativo	26	10884

Tabla 20.

Matriz de confusión para el sistema en general.

Sistema total		Resultado del clasificador	
		Positivo	Negativo
Instancia	Positivo	2653	627
Real	Negativo	110	33795

Los parámetros mostrados en las ecuaciones (11)-(16), son necesarios para describir el rendimiento del sistema (Fawcett, 2004), los cuales se describen a continuación:

- **Tasa de reales positivos (TRP):** Es la eficiencia en la clasificación con los elementos que son de la clase, también es conocido como Sensibilidad, y mientras su valor sea más cercano a 1, mejor será la clasificación.
- **Tasa de falsos negativos (TFN):** Muestra el comportamiento del sistema con los elementos que no son detectados, también es denominada como la tasa de pérdidas, y mientras su valor sea más cercano a 0, mejor será la clasificación.
- **Tasa de falsos positivos (TFP):** Muestra el comportamiento del sistema con los elementos que son incorrectamente detectados, también es denominada como la tasa de falsas alarmas, y mientras su valor sea más cercano a 0, mejor será la clasificación.
- **Tasa de reales negativos (TRN):** Es la eficiencia en la clasificación con los elementos que no son de la clase, también es conocido como Especificidad, y mientras su valor sea más cercano a 1, mejor será la clasificación.
- **Exactitud.-** Es la proximidad entre el resultado y la clasificación perfecta, mientras su valor sea más cercano a 1, mejor será la clasificación.
- **Precisión.-** Es la calidad de la respuesta del clasificador, mientras su valor sea más cercano a 1, mejor será la clasificación.

$$TPR = \frac{RP}{RP + FN} \quad (11)$$

$$TFN = \frac{FN}{RP + FN} \quad (12)$$

$$TRN = \frac{RN}{RN + FP} \quad (13)$$

$$TFP = \frac{FP}{RN + FP} \quad (14)$$

$$Exactitud = \frac{RP + RN}{RP + FN + RN + FP} \quad (15)$$

$$Presición = \frac{RP}{RP + FP} \quad (16)$$

Los resultados obtenidos de las pruebas de funcionamiento para diferentes condiciones climáticas y de iluminación, se muestran en la **Tabla 21**, con lo cual se determina si el sistema cumple con las condiciones de funcionamiento y en qué casos de iluminación se obtiene los mejores resultados.

Tabla 21.

Resultados del sistema respecto a la precisión y exactitud.

	TRP	TFN	TRN	TFP	Exactitud	Precisión
Día normal	0.87	0.13	0.997	0.003	0.98	0.97
Día soleado	0.72	0.28	0.995	0.005	0.97	0.90
Día nublado	0.79	0.21	0.997	0.003	0.97	0.96
Sistema total	0.81	0.19	0.997	0.003	0.98	0.96

Para analizar el desempeño del sistema propuesto, se grafica las curvas DET, que grafica tasa de falsos negativos en función de tasa de falsos positivos en escala logarítmica en el rango de 0.01-1% en el eje de la abscisa debido a la baja tasa de falsos positivos; en el eje de la ordenada el rango es de 1-100%. En la **Figura 64** se muestran los resultados experimentales para diferentes días con distintas condiciones de iluminación, estos resultados muestran que la tasa de pérdida (tasa de falsos negativos) más baja se tiene en días con iluminación normal con un valor de 12%, mientras que la tasa de pérdida más alta se da en días soleados, con un valor de 30%. Mientras, que el sistema en total tiene una tasa de pérdida de 19%. La tasa de falsos positivos muestra la falsa alarma que produce el sistema de acuerdo a la **Figura 64** se puede observar que los días nublados normal tienen el valor más bajo de falsa alarma con un 0.25%, mientras que los días soleados producen el valor más alto con un 0.45%. La falsa alarma que produce el sistema en general es de 0.3%.




Figura 64. Curva DET del funcionamiento del sistema total y para diferentes días con distintas condiciones de iluminación.

5.5 Tiempos de cómputo

Para determinar si la propuesta es apta para aplicaciones en tiempo real, se obtiene los tiempos de cómputo promedio del sistema, los resultados se muestran en la **Tabla 22**, donde se detallan los tiempos de la etapa de detección, reconocimiento y el de captura de la imagen e imprimir en pantalla el resultado a visualizar.

Tabla 22.

Tiempos de cómputo del sistema.

	Tiempo de cómputo
Tiempo de captura	1 ms
Tiempo de detección	16.38 ms
Tiempo de reconocimiento	7.99 ms
Tiempo de visualización	1 ms
Tiempo promedio del sistema	26.37 ms

5.6 Conclusiones del capítulo

De las pruebas de funcionamiento se determinó que el sistema funciona correctamente en diferentes condiciones climatológicas y de iluminación, en escenas complejas donde existen oclusiones y deterioro. La curva DET de la **Figura 64** muestra que el mejor desempeño del sistema fue en días en condición de iluminación normal con una precisión del 97%, mientras que el peor desempeño se da en días soleados con una precisión del 90%.

Observando de la **Tabla 22**, se deduce que el sistema es apto para trabajar en aplicaciones en tiempo real, debido que una cámara toma alrededor de 30 imágenes por segundo, eso quiere decir que cada imagen es captada cada 33.33ms y el tiempo del sistema es de 26.37 ms, siendo menor al tiempo requerido.

CAPÍTULO VI

6. CONCLUSIONES Y TRABAJOS FUTUROS

6.1 Conclusiones

En el presente trabajo de investigación se presentó un sistema automático de detección y reconocimiento de señales de tránsito en intersecciones viales Pare y Ceda el Paso en el Ecuador para aplicaciones en vehículos inteligentes.

Para el entrenamiento y validación del sistema se construyó una base de datos a partir de imágenes obtenidas en varias ciudades del Ecuador, en diferentes condiciones climáticas, de iluminación, rotaciones y oclusiones, para formar un clasificador lo suficientemente robusto ante estas situaciones, debido a que la mayoría de señales de tránsito no se encuentran en buenas condiciones, presentando deterioros, o no poseen las mismas propiedades de construcción, teniendo variaciones en el tono del color, en la proporción del tamaño de letras y en ocasiones hasta en la forma general de la señal de tránsito.

Primero se realizó un estudio de los espacios de color para escoger el espacio que minimice los efectos de los cambios de iluminación en escenas reales. Para este estudio se analizó la distribución de las componentes de 6 espacios de color, quedando como el mejor, el RGB normalizado con las componentes G_n y B_n . Los problemas que se tiene con este espacio de color son cuando los días son demasiado oscuros y cuando existe incidencia directa del sol sobre el equipo de percepción ya que causa deslumbramiento.

Luego, se definió dos clases, la de interés (color rojo) y la de no interés (otros colores). Para modelar las componentes G_n y B_n de cada una de las clases se utilizó el algoritmo de agrupamiento $K_m - means$, quedando como número de centroides K_m de 30 y 40 para la clase de interés y no interés, respectivamente. Para determinar el número de centroides se utilizan 4 métodos que proveen de un número aproximado para cada clase. Sin embargo, mediante la experimentación se llegó a determinar el

número final de centroides, para cada una de las clases, ya que los métodos son un buen punto de partida para llegar al resultado final.

La segmentación se realiza mediante la clasificación del color utilizando el algoritmo $k - NN$. Para entrenar este clasificador se utiliza las componentes modeladas G_n y B_n de cada una de las clases. Para determinar el valor del parámetro k , se analiza las curvas ROC y el AUC para distintos valores de k , quedando el valor de $k = 3$. Con este valor el sistema presenta los mejores resultados con un AUC de 0.986, y un tiempo de computo de 16.34 ms en imágenes de dimensiones de 640x480.

La última parte de la etapa de detección consiste en realiza un pos-procesamiento para disminuir el número de candidatos aplicando criterios de forma y área. Las regiones que no cumplan con un área mínima de 400 píxeles y una máxima de 10000 píxeles no serán consideradas como ROIs, estos valores se determinaron experimentalmente y corresponden a distancias de 20m y 5m, respectivamente. Otro criterio para reducir el número de ROIs es el de relación de aspecto que debe estar comprendido en el rango de 0.6-1.4. Las ROIs que cumplan estas especificaciones de área y forma se generan mediante un detector de bordes aplicando el operador Laplaciano para ser enviadas a la siguiente etapa.

El método de segmentación propuesto presenta mejores resultados cuando en las escenas existen colores con altas componentes del color rojo, por ejemplo el tomate y amarillo en comparación con el método propuesto por (Salti, Petrelli, Tombari, Fioraio, & Di Stefano, 2015) y (Zaklouta & Stanculescu, Real-time traffic sign recognition in three stages, 2014) los cuales utilizan la ecuación (1), para segmentar señales de tránsito de color rojo. Sin embargo, el otro método presenta una mayor robustez en escenas de días oscuros y tiene tiempos de cómputos más bajos que el método propuesto. Sin embargo, con el tiempo empleado en este proyecto la aplicación funciona correctamente en tiempo real. Estos resultados se pueden apreciar en el Anexo 2.

En la etapa de reconocimiento, primero, se utilizó el descriptor HOG para obtener las características más representativas de una señal de tránsito a través de la forma geométrica, con lo cual se obtuvo robustez ante las escenas con diferente tamaño y con

condiciones de iluminación variable, para ello se construyeron varias versiones de HOG, con diferentes tamaños de celda y orientaciones, de lo cual se determinó que los vectores HOG con tamaño de celda de 8x8 píxeles tuvo los mejores resultados con un costo computacional menor. Los vectores HOG con tamaño de 2x2 y 4x4 píxeles ofrecen buenos resultados, pero con un costo computacional muy alto. Para vectores HOG con tamaño de celda de 16x16 píxeles el clasificador tiene un mal desempeño.

La clasificación de las señales de tránsito se la realizó por medio de SVM; el entrenamiento y validación se realizó para diferentes núcleos. Experimentalmente que las características HOG con un tamaño de imagen de 32x32 píxeles, tamaño de celda de 8x8 píxeles, tamaño de bloque de 2x2 celdas, solapamiento de celdas simple, 9 orientaciones y clasificador SVM con núcleo polinómico generan los mejores resultados,

Posteriormente, se determinó que el sistema es apto para aplicaciones en tiempo real, debido a que una cámara convencional obtiene 30 imágenes por segundo, por lo tanto, el tiempo que se tiene entre imágenes es de 33.33 ms, y el tiempo promedio que emplea el sistema desarrollado es de 26.86 ms, incluido el tiempo que se tarda en adquirir la imagen, y mostrar el resultado, el tiempo obtenido es un promedio de todos los tiempos, ya que depende de la escena en la que se encuentre. Las situaciones en la que el tiempo de cómputo fue alto es en las escenas que poseen muchas ROIs a clasificar, cuando la escena posee mucha concentración de color rojo y en días soleados cuando el sol incide directamente sobre la cámara.

Finalmente, mediante pruebas desarrolladas, en tiempo real, se pudo establecer que el sistema tiene un mejor funcionamiento en días con iluminación normal, mientras que tiene el peor desempeño en días soleados, especialmente cuando el sol incide directamente sobre el equipo de percepción causando deslumbramiento. La tasa de pérdidas para días con iluminación normal es 12%, para días soleados 30% y para días oscuros 20%.

6.2 Trabajos futuros

El presente trabajo de investigación es un buen punto de partida para desarrollo de ADAS más completos, confiables y fiables, por lo que existen algunos trabajos que se pueden realizar para mejorar y completar el sistema propuesto son:

- Incluir todas las señales de tránsito reglamentarias para la etapa de reconocimiento, debido a que la etapa de detección segmenta todas las señales que tienen el color rojo.
- Mejorar la etapa de detección de señales de tránsito en caso de oclusión parcial, en días oscuros, o ambientes con baja iluminación.
- Desarrollar un método para minimizar los efectos del deslumbramiento cuando el sol incide directamente sobre el sistema de percepción.

BIBLIOGRAFÍA

- Agencia Nacional de Tránsito. (2010). *Normas y Reglamentos Inen aplicados al Transporte*. Recuperado el 10 de Marzo de 2016, de Tránsito: <http://www.ant.gob.ec/index.php/servicios/normas-y-reglamentos-inen/transito>
- Agencia Nacional de Tránsito. (19 de Noviembre de 2012). *Accidentes de tránsito general*. Recuperado el 22 de Marzo de 2016, de Comparación internacional: <http://www.ant.gob.ec/index.php/descargable/file/286-12-comparacin-andina>
- Agencia Nacional de Tránsito. (24 de Junio de 2016). *Accidentes 2016*. Recuperado el 8 de Julio de 2016, de Estadísticas: <http://www.ant.gob.ec/index.php/descargable/category/223-accidentes2016>
- Agencia Nacional de Tránsito. (7 de Marzo de 2016). *Fallecidos diciembre 2015*. Recuperado el 1 de Abril de 2016, de Fallecidos a diciembre 2015: <http://www.ant.gob.ec/index.php/descargable/file/3367-fallecidos-diciembre-2015>
- Agencia Nacional de Tránsito. (30 de Marzo de 2016). *Rendición de Cuentas*. Recuperado el 8 de Abril de 2016, de Rendición de Cuentas 2015: <http://www.ant.gob.ec/index.php/descargable/file/3536-rendicion-de-cuentas-2015>
- Aoyagi, Y., & Asakura, T. (1996). A study on traffic sign recognition in scene image using genetic algorithms and neural networks. *Industrial Electronics, Control, and Instrumentation*, 1838-1843.
- Bertozzi, M., Broggi, A., Del Rose, M., Felisa, M., Rakotomamonjy, A., & Suard, F. (2007). A Pedestrian Detector Using Histograms of Oriented Gradients. *IEEE Intelligent Transportation Systems Conference*, 143-148.
- Caliński, T., & Harabasz, J. (1974). A dendrite method for cluster analysis. *Communications in Statistics-theory and Methods*, 1-27.
- Carrasco Pascual, J. P. (2009). *Advanced Driver Assistance System based on Computer Vision using Detection, Recognition and Tracking of Road Signs*. Madrid, España: Universidad Carlos III de Madrid.
- Cortes, C., & Vapnik, V. (1995). Support-Vector Networks. *Machine Learning*, 273-297.
- Dalal, N., & Triggs, B. (2005). Histograms of Oriented Gradients for Human Detection. *Computer Vision and Pattern Recognition*, 886-893.
- Davies, D., & Bouldin, D. (1979). A Cluster Separation Measure. *IEEE transactions on pattern analysis and machine intelligence*, 224-227.
- Duda, R., Hart, P., & Stork, D. (2001). *Pattern Classification*. John Wiley & Sons.

- El tiempo. (29 de Agosto de 2008). *Siemens desarrolló un lector de señales de tránsito que de acuerdo a estas controla el comportamiento del vehículo*. Recuperado el 22 de Septiembre de 2016, de <http://www.eltiempo.com/archivo/documento/CMS-4488444>
- Fang, C., Chen, S., & Fuh, C. (2003). Road-sign detection and tracking. *IEEE transactions on vehicular technology*, 1329-1341.
- Fawcett, T. (2004). ROC graphs: Notes and practical considerations for researchers. *Machine learning*, 1-38.
- Fleyeh, H., Biswas, R., & Davami, E. (2013). Traffic sign detection based on AdaBoost color segmentation and SVM classification. *EUROCON*, 2005-2010.
- Gómez Moreno, H., Maldonado Bascón, S., Gil Jiménez, P., & Lafuente Arroyo, S. (2010). Goal Evaluation of Segmentation Algorithms. *IEEE Transactions on Intelligent Transportation Systems*, 917-930.
- González Marcos, A., Martínez de Pisón Ascacíbar, F. J., Pernía Espinoza, A. V., Alba Elías, F., Castejón Limas, M., Ordieres Meré, J. B., & Vergara González, E. P. (2006). *Técnicas y Algoritmos Básicos de Visión Artificial*. España: Universidad de La Rioja.
- Gonzalez, R., & Woods, R. (2008). *Digital Image Processing*. Prentice Hall.
- Greenhalgh, J., & Mirmehdi, M. (2012). Real-Time Detection and Recognition of Road Traffic Signs. *IEEE TRANSACTIONS ON INTELLIGENT TRANSPORTATION SYSTEMS*, 1498-1506.
- Hsu, C.-W., Chang, C.-C., & Lin, C.-J. (2003). A practical guide to support vector classification. *Department of Computer Science*, 1-16.
- Huang, Z., Yu, Y., & Gu, J. (2014). A Novel Method for Traffic Sign Recognition based on Extreme Learning Machine. *11th World Congress on Intelligent Control and Automation*, 1451-1456.
- Instituto Nacional de Estadística y Censo. (s.f.). *Anuario de estadísticas vitales nacimientos y defunciones 2014*. Recuperado el 28 de Marzo de 2016, de Ecuador en cifras: http://www.ecuadorencifras.gob.ec/documentos/web-inec/Poblacion_y_Demografia/Nacimientos_Defunciones/Publicaciones/Anuario_Nacimientos_y_Defunciones_2014.pdf
- iTunes. (09 de Marzo de 2016). *myDriveAssist – Bosch Detección de señales de tráfico con tu móvil!* Recuperado el 22 de Septiembre de 2016, de <https://itunes.apple.com/es/app/mydriveassist-bosch-deteccion/id586161771?mt=8>
- Jiménez, F., Gómez, Ó., Naranjo, J. E., Serradilla, F., López, J. M., & Martín, Á. (Septiembre de 2011). *Sistemas Avanzados de Asistencia al Conductor*.

Revista Informativa del Colegio Oficial de Ingenieros Industriales de Madrid, 22-27.

- Kellmeyer, D., & Zwahlen, H. (1994). Detection of highway warning signs in natural video images using color image processing and neural networks. *IEEE World Congress on Computational Intelligence*, 4226-4231.
- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. *International Joint Conference on Artificial Intelligence*, 1137-1145.
- Kouzani, A. (2007). Road-Sign Identification Using Ensemble Learning. *IEEE Intelligent Vehicles Symposium*, 438-443.
- Kuo, W.-J., & Lin, C.-C. (2007). Two-stage road sign detection and recognition. *IEEE International Conference on Multimedia and Expo*, 1427-1430.
- Li, H., Sun, F., Liu, L., & Wang, L. (2015). A novel traffic sign detection method via color segmentation and robust shape matching. *Neurocomputing*, 77-88.
- Lillo Castellano, J. M. (2010). *Detección Automática de Señales de Tráfico Mediante Procesamiento Digital de Imagen*. Madrid, España: Universidad Rey Juan Carlos.
- Lillo Castellano, J., Mora Jiménez, I., Figuera Pozuelo, C., & Rojo Álvarez, J. (2015). Traffic sign segmentation and classification using statistical learning methods. *Neurocomputing*, 286-299.
- Loy, G., & Barnes, N. (2004). Fast shape-based road sign detection for a driver assistance system. *Intelligent Robots and Systems*, 70-75.
- Maldonado-Bascón, S., Lafuente-Arroyo, S., Gil-Jiménez, P., Gómez-Moreno, H., & López-Ferreras, F. (2007). Road-sign detection and recognition based on support vector machines. *IEEE transactions on intelligent transportation systems*, 264-278.
- Mammeri, A., Boukerche, A., & Almulla, M. (2013). Design of traffic sign detection, recognition, and transmission systems for smart vehicles. *IEEE Wireless Communications*, 36-43.
- Martin, A., Doddington, G., Kamm, T., Ordowski, M., & Przbocki, M. (1997). The DET curve in assessment of detection task performance. *NATIONAL INST OF STANDARDS AND TECHNOLOGY GAITHERSBURG MD*.
- Mendieta, V. A. (2013). *Detección y Reconocimiento de Semáforos por Visión Artificial*. Madrid, España: Universidad Carlos III de Madrid.
- Mercedes-Benz. (s.f.). *Reconocimiento automático de señales de tráfico*. Recuperado el 22 de Septiembre de 2016, de http://techcenter.mercedes-benz.com/es_ES/traffic_sign_assist/detail.html#intro-section

- Michell, T. (1997). *Machine Learning*. Porland, Estados Unidos: McGraw Hill.
- Ministerio de Transportes y Comunicaciones del Perú. (s.f.). *Sistemas Inteligentes de Transporte*. Recuperado el 7 de Abril de 2016, de http://www.proviasnac.gob.pe/Archivos/file/Documentos_de_Interes/ITS-UGOP2.pdf
- Møgelmoose, A., Liu, D., & Trivedi, M. M. (2015). Detection of U.S. Traffic Signs. *IEEE Transactions on Intelligent Transportation Systems*, 3116-3125.
- Nguwi, Y.-Y., & Kouzani, A. (2008). Detection and classification of road signs in natural environments. *Neural computing and applications*, 265-289.
- Organización Mundial de la Salud. (2015). *Informe sobre la situación mundial de la seguridad vial 2015*. Recuperado el 5 de Abril de 2016, de Resumen: http://www.who.int/entity/violence_injury_prevention/road_safety_status/2015/Summary_GSRRS2015_SPA.pdf?ua=1
- Organización Mundial de la Salud. (Mayo de 2016). *Centro de prensa*. Recuperado el 18 de Junio de 2016, de Lesiones causadas por el tránsito: <http://www.who.int/mediacentre/factsheets/fs358/es/>
- 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/
- Pajares, G., & de la Cruz, J. (2002). *Visión por Computador Imágenes digitales y aplicaciones*. Madrid, España: RA-MA.
- Piccioli, G., De Micheli, E., Parodi, P., & Campani, M. (1996). Robust method for road sign detection and recognition. *Elseiver*, 209-223.
- Ponce Cruz, P. (2010). *Inteligencia Artificial con Aplicaciones a la Ingeniería*. Mexico: Alfaomega.
- Real Academia Española. (s.f.). *Diccionario de la lengua española*. Recuperado el 10 de Marzo de 2016, de Edición del Tricentenario: www.rae.es
- Rousseeuw, P. (1987). Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. *Journal of computational and applied mathematics*, 53-65.
- Ruta, A., Li, Y., & Liu, X. (2010). Real-time traffic sign recognition from video by class-specific discriminative features. *Pattern Recognition*, 416-430.
- Salti, S., Petrelli, A., Tombari, F., Fioraio, N., & Di Stefano, L. (2015). Traffic sign detection via interest region extraction. *Pattern Recognition*, 1039–1049.
- Schimid, C., Mohr, R., & Bauckhage, C. (2000). Evaluation of Interest Point Detectors. *International Journal of computer vision*, 151-172.
- Sistemas Inteligentes de Transporte Chile. (s.f.). *Descripción ITS*. Recuperado el 15 de Abril de 2016, de <http://www.itschile.cl/paginas/descripcion.html>

- Suard, F., Rakotomamonjy, A., Bensrhair, A., & Broggi, A. (2006). Pedestrian detection using infrared images and histograms of oriented gradients. *IEEE Intelligent Vehicles Symposium*, 206-212.
- Sucar, E., & Gómez, G. (2011). *Visión Computacional*. Puebla, México: Instituto Nacional de Astrofísica, Óptica y Electrónica.
- Tibshirani, R., Walther, G., & Hastie, T. (2001). Estimation the number of clusters in a data set via the gap statistic. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 411-423.
- Tkalcic, M., & Tasic, J. (2003). Colour spaces: perceptual, historical and applicational background. *Eurocon*.
- Tomasi, C. (2015). Histograms of Oriented Gradients.
- Universidad de Barcelona. (1 de Agosto de 2004). *Los Sistemas Inteligentes De Transporte y sus Efectos* . Recuperado el 07 de Abril de 2016, de <http://www.ub.edu/geocrit/sn/sn-170-60.htm>
- Vanrell, M. (s.f.). *Introduccion a la Deteccion de Objetos*. Recuperado el 4 de 03 de 2016, de <https://www.coursera.org/learn/deteccion-objetos/home/week/1>
- Yin, S., Ouyang, P., Liu, L., Guo, Y., & Wei, S. (2015). Fast Traffic Sign Recognition with a Rotation Invariant Binary. *Sensors*, 2161-2180.
- Zaklouta, F., & Stanciulescu, B. (2012). Real-Time Traffic-Sign Recognition Using Tree Classifiers. *IEEE Transactions on Intelligent Transportation Systems*, 1507-1514.
- Zaklouta, F., & Stanciulescu, B. (2014). Real-time traffic sign recognition in three stages. *Robotics and Autonomous Systems*, 1507-1514.
- Zin, T. T., & Hama, H. (2004). Robust road sign recognition using standard deviation. *IEEE International Conference on Intelligent Transportation Systems*, 429-434.