



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: IMPLEMENTACIÓN DE UN ALGORITMO PARA DETECTAR SEÑALES DE TRÁNSITO PROHIBITIVAS Y REGLAMENTARIAS DEL ECUADOR USANDO UNA RED CONVOLUCIONAL RÁPIDA PARA APLICACIONES EN VEHÍCULOS INTELIGENTES

AUTORES:

**AYALA FARFÁN, MARÍA JOSÉ
GALLEGOS VALENZUELA, JOSELYN ESTEFANÍA**

DIRECTOR: DR. FLORES CALERO, MARCO JAVIER

SANGOLQUÍ

2018



ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

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

CERTIFICACIÓN

Certifico que el trabajo de titulación, ***“IMPLEMENTACIÓN DE UN ALGORITMO PARA DETECTAR SEÑALES DE TRÁNSITO PROHIBITIVAS Y REGLAMENTARIAS DEL ECUADOR USANDO UNA RED CONVOLUCIONAL RÁPIDA PARA APLICACIONES EN VEHÍCULOS INTELIGENTES”*** fue realizado por las señoritas ***AYALA FARFÁN, MARÍA JOSÉ*** y ***GALLEGOS VALENZUELA, JOSELYN ESTEFANÍA***, el mismo ha sido revisado en su totalidad, analizado por la herramienta de verificación de similitud de contenido; por lo tanto cumple con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Universidad de Fuerzas Armadas ESPE, razón por la cual me permito acreditar y autorizar para que lo sustenten públicamente.

Sangolquí, 26 de junio de 2018

Firma:

Ing. Marco Javier Flores Calero PhD.

C.C. 050219875-7



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

AUTORÍA DE RESPONSABILIDAD

Nosotras, *AYALA FARFÁN, MARÍA JOSÉ*, y *GALLEGOS VALENZUELA, JOSELYN ESTEFANÍA*, declaramos que el contenido, ideas y criterios del trabajo de titulación: *“IMPLEMENTACIÓN DE UN ALGORITMO PARA DETECTAR SEÑALES DE TRÁNSITO PROHIBITIVAS Y REGLAMENTARIAS DEL ECUADOR USANDO UNA RED CONVOLUCIONAL RÁPIDA PARA APLICACIONES EN VEHÍCULOS INTELIGENTES”* es de nuestra autoría y responsabilidad, cumpliendo con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Universidad de las Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

Consecuentemente el contenido de la investigación mencionada es veraz.

Sangolquí, 26 de junio de 2018

.....
María José Ayala Farfán
CC: 1724970387

.....
Joselyn Estefanía Gallegos Valenzuela
CC: 1726545674



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

AUTORIZACIÓN

Nosotras, *AYALA FARFÁN, MARÍA JOSÉ* y *GALLEGOS VALENZUELA, JOSELYN ESTEFANÍA*, autorizamos a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: *“IMPLEMENTACIÓN DE UN ALGORITMO PARA DETECTAR SEÑALES DE TRÁNSITO PROHIBITIVAS Y REGLAMENTARIAS DEL ECUADOR USANDO UNA RED CONVOLUCIONAL RÁPIDA PARA APLICACIONES EN VEHÍCULOS INTELIGENTES”* en el Repositorio Institucional, cuyo contenido, ideas y criterios son de nuestra autoría y responsabilidad.

Sangolquí, 26 de junio de 2018

.....
María José Ayala Farfán
CC: 1724970387

.....
Joselyn Estefanía Gallegos Valenzuela
CC: 1726545674

DEDICATORIAS

A mis padres Pepe y Yelis por ser mí pilar, motivación y fuerza; a mi padre por enseñarme el valor de las cosas, que nada es fácil pero con dedicación, esfuerzo y perseverancia todo es posible; a mi madre por sus consejos, apoyo, mimos y por tener siempre una palabra de aliento en momentos difíciles; los amo y son la bendición más bonita de mi vida gracias por tanto.

A mis hermanos, Karen, Jossue y Arleth; son mis pequeños y siempre podrán contar conmigo como su hermana mayor y que mejor como una amiga, gracias por alegrar mi vida.

A mi tía Yessica, una de mis personas favoritas siempre sacándome una sonrisa y por sus grandes consejos.

A mi primo Carlos, eres como un hermano mayor para mí y sin duda alguna, tus ocurrencias me han hecho reír tantas veces que no podría contarlas.

A toda mi familia, siempre me motivaron y apoyaron para que siga adelante y pueda culminar esta etapa, mil gracias también a ustedes.

María José Ayala Farfán

DEDICATORIAS

A:

Dios, por estar conmigo a lo largo de esta etapa estudiantil, por iluminar mi mente y por haber puesto en mi camino a las personas indicadas.

Mis padres, Edgar y Janeth, por su apoyo incondicional, por ser ejemplo de constancia y perseverancia, pero, sobre todo, por su amor.

Mis hermanas Jennyfer y Melany, porque son mi motivación más grande.

Joselyn Estefanía Gallegos Valenzuela

AGRADECIMIENTOS

Agradezco a Dios por mí vida, la de mis padres y hermanos para que puedan acompañarme en la culminación de esta etapa; por cada una de sus bendiciones y fuerzas para seguir adelante y por mantener a mi familia unida a pesar de todo.

A mis padres, toda esta vida no me alcanzaría para agradecerles todo lo que han hecho y siguen haciendo por mí, todo lo que tengo y lo que soy es gracias a ustedes, soy la persona más afortunada de tenerlos conmigo y espero sea así muchos años más. A mi hermana Karen por brindarme siempre su apoyo a pesar de las peleas sé que deseas lo mejor para mí así como yo lo deseo para ti, a mis pequeños Jossue y Arleth son personas de luz en mi vida.

A mis amigos, no podría nombrarlos a todos, pero han sido una parte muy importante en toda esta etapa, gracias por su apoyo, por compartir sus conocimientos conmigo, por su tiempo, confianza y por creer en mí incluso cuando yo no lo hacía, son realmente importantes en mi vida.

A mi compañera de tesis, Joselyn que más que una compañera se convirtió en una gran amiga, gracias por escucharme, apoyarme y aconsejarme para que siempre busque lo mejor y lo que me haga sentir bien.

Al Dr. Marco Flores por los conocimientos compartidos en el transcurso de este proyecto.

María José Ayala Farfán

AGRADECIMIENTOS

Agradezco a Dios, por su fidelidad, por renovar mis fuerzas cada mañana, por ser mi guía, por su amor y por la mayor bendición que me ha dado, mi familia. Gracias Padre, porque sin ti, no soy nada.

A mis padres, gracias por sus consejos, por los valores que me han inculcado a lo largo de la vida y por enseñarme el verdadero valor de las cosas. Gracias por cada, alimento, por cada palabra, por cada abrazo y por cada acción que han hecho de mi la mujer que soy. A mis hermanas, gracias por alegrar mi vida, y por estar conmigo en las buenas y en las malas. Los amo con todo mi corazón.

A mis abuelos, tíos y primos, gracias por creer en mí.

A María José, por su ayuda en la realización de este trabajo, pero más allá de eso, gracias por compartir tu tiempo, tus oídos, y tus palabras conmigo.

A mis amigos, Paola, María José, Darwin, Cristhian y Javier, gracias por su apoyo y por cada momento compartido.

Al Dr. Marco Flores, por su guía, y el tiempo dedicado para que este proyecto pueda culminar con éxito.

Joselyn Estefanía Gallegos Valenzuela

ÍNDICE DE CONTENIDOS

CERTIFICACIÓN	i
AUTORÍA DE RESPONSABILIDAD	ii
AUTORIZACIÓN.....	iii
DEDICATORIAS.....	iv
AGRADECIMIENTOS	vi
RESUMEN.....	xv
ABSTRACT	xvi
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.....	3
1.2.2 Accidentes de tránsito en el Ecuador	8
1.3 Tipos de señales de tránsito en el Ecuador.....	13
1.3.1 Normalización de señales de tránsito por color	15
1.3.2 Normalización de señales de tránsito por forma	16
1.4 Sistemas inteligentes de transporte	17
1.5 Justificación e importancia.....	18
1.6 Alcance del proyecto	21

1.7	Objetivos	23
1.7.1	Objetivo general	23
1.7.2	Objetivos específicos.....	23
1.8	Estructura del documento.....	23
CAPÍTULO II.....		25
2.	ESTADO DEL ARTE.....	25
2.1	Introducción	25
2.2	Detección de señales de tránsito.....	25
2.2.1	Segmentación a través del color.....	26
2.2.2	Segmentación a través de la forma.....	27
CAPÍTULO III.....		30
3.	CLASIFICACIÓN DE PÍXELES USANDO COLOR	30
3.1	Introducción	30
3.2	Sub-etapa de pre-procesamiento	31
3.2.1	Ecualización de histograma de la imagen	32
3.3	Segmentación multicolor usando $k - NN$ con $Km - means$ en condiciones de iluminación variable.....	35
3.3.1	Mejora de detección de píxeles usando el espacio de color HSV	37
3.4	Sub-etapa de post-procesamiento.....	38
3.5	Parámetros finales para funcionamiento de etapa de detección.....	39
3.6	Generación de ROIs	45

CAPÍTULO IV	46
4. CLASIFICACIÓN DE SEÑALES DE TRÁNSITO PREVENTIVAS Y REGLAMENTARIAS	46
4.1 Redes Convolucionales	46
4.2 Arquitectura Fast RCNN	48
4.3 Descripción de arquitectura Fast R-CNN para la clasificación de señales de tránsito ..	54
4.4 Parámetros de entrenamiento de la red	57
4.5 Base de datos	57
CAPÍTULO V	58
5. PRUEBAS Y RESULTADOS	58
5.1 Introducción	58
5.2 Herramientas utilizadas para la evaluación del detector	58
5.2.1 Precisión	58
5.2.2 Recuperación (Recall)	59
5.2.3 Curvas ROC (Característica Operativa del Receptor).....	59
5.2.4 Tasa de error versus Falsos Positivos Por Imagen (FPPI)	60
5.2.5 Media de la Precisión Promedio (mAP).....	61
5.3 Evaluación del sistema de detección	61
5.3.1 Evaluación etapa de clasificación de píxeles usando color	61
5.3.2 Evaluación del método de generación de ROIs	68
5.4 Evaluación etapa de clasificación	74
5.5 Evaluación del detector de señales de tránsito	74

5.6	Ejemplos de funcionamiento de detección de señales de tránsito.....	77
CAPÍTULO VI		82
6.	CONCLUSIONES Y RECOMENDACIONES	82
6.1	Conclusiones	82
6.2	Recomendaciones.....	83
6.3	Trabajos futuros.....	83
7.	BIBLIOGRAFÍA.....	84

ÍNDICE DE TABLAS

Tabla 1. <i>Parámetros de tamaño que debe cumplir una ROI</i>	38
Tabla 2. <i>Resumen del entrenamiento de Arquitecturas base para este trabajo</i>	49
Tabla 3. <i>Resultados del entrenamiento al modificar la red Alexnet</i>	51
Tabla 4. <i>Arquitectura propuesta para clasificación de señales de tránsito</i>	54
Tabla 5. <i>Parámetros de entrenamiento de la arquitectura del sistema 1</i>	57
Tabla 6. <i>Confirmación de ROIs válidas en un fotograma</i>	71
Tabla 7. <i>Evaluación del método de generación de ROIs en videos</i>	73
Tabla 8. <i>Valores de AP para cada señal</i>	75

ÍNDICE DE FIGURAS

Figura 1. <i>Muertes por accidentes de tránsito según tipo de usuario (2013)</i>	5
Figura 2. <i>Tasas de mortalidad por región</i>	6
Figura 3. <i>Porcentajes de población, 2013.</i>	7
Figura 4. <i>Tasa de mortalidad en la Región de las Américas.</i>	7
Figura 5. <i>Número de vehículos matriculados, 2008-2015.</i>	9
Figura 6. <i>Número de accidentes de tránsito en Ecuador, 2008-2016</i>	9
Figura 7. <i>Accidentes de tránsito según la provincia, 2014-2016.</i>	10
Figura 8. <i>Número de accidentes de tránsito, por meses, año 2016.</i>	10
Figura 9. <i>Distribución según su clase.</i>	11
Figura 10. <i>Distribución en base a la causa.</i>	12
Figura 11. <i>Número de heridos en base a la causa.</i>	12

<i>Figura 12.</i> Número de muertos en base a la causa, año 2016.	13
<i>Figura 13.</i> Principales señales de tránsito del Ecuador.	14
<i>Figura 14.</i> Siniestros de tránsito.	19
<i>Figura 15.</i> Vehículos involucrados.	19
<i>Figura 16.</i> Fallecidos.	20
<i>Figura 17.</i> Lesionados.	21
<i>Figura 18.</i> Lesionados, tipo de vehículos.	21
<i>Figura 19.</i> Esquema propuesto para localizaciones de candidatos.	30
<i>Figura 20.</i> Distribución de píxeles espacio de color RGB normalizado.	31
<i>Figura 21.</i> Esquema de la Técnica CLAHE.	33
<i>Figura 22.</i> Mejora del contraste con los ecualizadores global y CLAHE.	34
<i>Figura 23.</i> Distribución de los colores de interés y no interés.	36
<i>Figura 24.</i> Distribución de los centroides para las clases de interés y no interés.	40
<i>Figura 25.</i> Segmentación de señal de tránsito.	41
<i>Figura 26.</i> Segmentación mediante K-NN y filtro usando espacio de color HSV.	41
<i>Figura 27.</i> Generación de ROIs día normal.	42
<i>Figura 28.</i> Generación de ROIs día nublado.	43
<i>Figura 29.</i> Generación de ROIs día soleado.	44
<i>Figura 30.</i> Comprobación de ROIs válidas.	45
<i>Figura 31.</i> Comprobación de ROIs válidas.	45
<i>Figura 32.</i> Ejemplo de una arquitectura simple de red convolucional.	47
<i>Figura 33.</i> Esquema general de clasificación de señales de tránsito.	48
<i>Figura 34.</i> Curvas ROC de arquitecturas base.	49

<i>Figura 35.</i> Curva ROC al disminuir 4 capas	54
<i>Figura 36.</i> Arquitectura Fast-RCNN propuesta para clasificación señales de tránsito	56
<i>Figura 37.</i> Curvas ROC usando K-NN.	63
<i>Figura 38.</i> Curvas ROC usando filtro en espacio de color HSV.....	65
<i>Figura 39.</i> Curvas ROC usando K-NN más filtro en espacio de color HSV.	67
<i>Figura 40.</i> Comprobación ROIs válidas.....	69
<i>Figura 41.</i> Comprobación ROIs válidas.....	69
<i>Figura 42.</i> Resultado generación de ROIs.....	70
<i>Figura 43.</i> Curva ROC para clasificación.	74
<i>Figura 44.</i> Tasa de error versus FPPI.....	76
<i>Figura 45.</i> Ejemplos de funcionamiento con iluminación normal	77
<i>Figura 46.</i> Ejemplos de funcionamiento con iluminación al amanecer	78
<i>Figura 47.</i> Ejemplos de funcionamiento durante días nublados	79
<i>Figura 48.</i> Ejemplos de funcionamiento durante la noche.....	80
<i>Figura 49.</i> Ejemplos de falsas detecciones con el sistema 1.....	81

RESUMEN

Los accidentes de tránsito son una de las principales causas de muerte tanto en Ecuador como en el mundo, siendo los usuarios viales más vulnerables los peatones, ciclistas y motociclistas; con la finalidad de mejorar la seguridad de todos los usuarios y evitar posibles accidentes se encuentran en desarrollo nuevas tecnologías mediante los Sistemas Avanzados de Asistencia a la Conducción (ADAS). La siguiente investigación presenta el desarrollo de un sistema automático de detección de señales de tránsito preventivas y reglamentarias, dividida en dos etapas, la primera etapa consiste en la generación de regiones de interés (ROIs) las cuales contienen posibles candidatos a una señal de tránsito, para ello se utilizó el espacio de color RGB normalizado y el algoritmo de clasificación K-NN, para realizar la segmentación de los colores de interés rojo y amarillo; la segunda etapa consiste en la clasificación y reconocimiento de la señal de tránsito, utilizando una Red Neuronal Convolutiva Rápida (Fast-RCNN en inglés), con 3 capas de convolución, 3 capas de agrupamiento (max-pooling) y 3 capas totalmente conectadas (Full Connection-FC). Para evaluar el funcionamiento del sistema, se utilizaron las curvas de Característica Operativa del Receptor (ROC), para medir la capacidad de detección se usó la curva tasa de error versus Falsos Positivos Por Imagen (FPPI) y la Media de la Precisión Promedio (mAP). Los resultados son 97.6% para clasificación de color, un mAP del 75% para clasificación de señales de tráfico y una tasa de error de 0.33 en 10-1 FPPI para la detección.

PALABRAS CLAVE

- **ADAS**
- **$K - NN$**
- **ROI**
- **FAST-RCNN**

ABSTRACT

Traffic accidents are one of the main causes of death both in Ecuador and in the world, being road users more vulnerable pedestrians, cyclists and motorcyclists; In order to improve the safety of all users and prevent possible accidents, new technologies are being developed through the Advanced Driving Assistance Systems (ADAS). The following research presents the development of an automatic detection system for preventive and regulatory traffic signals, divided into two stages, the first stage consists in the generation of regions of interest (ROIs) which contain possible candidates for a traffic signal, for this, the standardized RGB color space and the K-NN classification algorithm were used to segment the red and yellow colors of interest; the second stage consists in the classification and recognition of the transit signal, using a Fast Convolutional Neural Network (Fast-RCNN), with 3 layers of convolution, 3 layers of grouping (max-pooling) and 3 Full Connection Layers (FC). In order to evaluate the performance of the system, were used the operating characteristic curves of the receiver (ROC), to measure the detection capacity, were used the error rate versus the False Positive Per Image (FPPI) curve and the Mean Average Precision (mAP). The results are 97.6% for color classification, mAP of 75% for classification of traffic signals and an error rate of 0.33 in 10-1 FPPI for detection.

KEYWORDS

- **ADAS**
- ***K – NN***
- **ROI**
- **FAST-RCNN**

CAPÍTULO I

1. INTRODUCCIÓN

1.1 Antecedentes

Las señales de tránsito son de suma importancia en el sistema de circulación vehicular, ya que proveen al conductor de información acerca de las normas y reglamentos de tránsito, advirtiéndolo de potenciales peligros que pueden aparecer en la vía y comunicando otro tipo de información que facilite la conducción. Su detección y reconocimiento resulta de especial interés en multitud de aplicaciones empresariales relacionadas con el mantenimiento de la infraestructura vial, y el desarrollo de vehículos autónomos e inteligentes (František Duchon, 2012).

Hoy en día casi el 6% de accidentes de tránsito se producen debido a la imprudencia de los conductores por no prestar la debida atención a las señales de tráfico que se presentan en la vía (Agencia Nacional de Tránsito, 2008-2016). Este sistema pretende evitar que las señales de tráfico pasen desapercibidas y poder advertir al conductor sobre la señalética existente en su camino para que la tome en cuenta y pueda realizar las acciones pertinentes.

En comparación con la clasificación de imágenes, la detección de señales de tránsito es una tarea más desafiante que requiere métodos más complejos. La complejidad surge porque la detección requiere la localización precisa de las señales, y para resolver estos problemas a menudo se comprometen la velocidad, la precisión o la simplicidad (Arriagada García & Aracena Pizarro, 2007).

Para lograr este objetivo, se han realizado varias investigaciones desde hace algunas décadas, descubriendo métodos como el Deep Learning (Bengio, 2009), con el cual se pretende simular en

una máquina el comportamiento del cerebro humano, por lo que estos métodos se denominan métodos de clasificación automática, donde no es necesaria la intervención humana para la generación de características ni para el entrenamiento del algoritmo de clasificación.

Actualmente entre los métodos más utilizados para ejecutar la clasificación automática de señales de tráfico se encuentran CNN (Convolutional Neural Networks for Visual Recognition) y Fast R-CNN (Girshick, 2015) los cuales realizan la extracción de características y la clasificación en un solo proceso de aprendizaje, a pesar de que su costo computacional es mucho más alto que cualquier otro método, éstos son capaces de lograr mayor exactitud y mejor latencias en general, siendo su mayor beneficio el tiempo que se ahorra en el entrenamiento y en su ejecución por lo que se vuelven un buen candidato para aplicaciones en tiempo real.

1.2 Accidentes de tránsito

Un accidente de tránsito es un evento que ocasiona un daño involuntario alterando el estado habitual de usuarios viales y de vehículos en una carretera (Real Academia Española, s.f.).

Los accidentes de tránsito son una de las causas de muerte más significativas en el mundo; es por esto que cada año se registran muertes de aproximadamente 1,25 millones de personas. Alrededor de 20 y 50 millones de personas sufren algún tipo de traumatismo no mortal, mientras que en otros casos se llega a adquirir alguna discapacidad. Cada día mueren alrededor de 3500 personas en las carreteras; y son los niños, los ancianos, peatones y ciclistas los que se encuentran en el grupo de personas más vulnerables en la vía, según el informe acerca de la situación mundial de la seguridad vial 2015 (Organización Mundial de la Salud, 2015).

1.2.1 Accidentes de tránsito en el mundo

“Los accidentes de tránsito se cobran un número inaceptable de víctimas, especialmente entre las personas pobres de los países pobres” dice la Dra. Margaret Chan, directora de la Organización Mundial de la Salud (OMS). Dentro del grupo de usuarios más vulnerables en las carreteras se encuentran los motociclistas, representando hasta un 23%; los peatones un 22% y los ciclistas un 4% de las defunciones en todo el mundo (Organización Mundial de la Salud, 2015).

Del 8 al 14 de mayo de 2017, se celebró la cuarta Semana Mundial de las Naciones Unidas para la Seguridad Mundial, con el fin de reducir el número de traumatismos y muertes causadas por accidentes de tránsito, alertando principalmente sobre el exceso de velocidad dado que este problema representa 1 de cada 3 muertes en las vías en aquellos países cuyos ingresos son altos y la mitad en países de ingresos medios y bajos (Organización Panamericana de la Salud, 2017).

1.2.1.1 Datos sobre la seguridad vial en el mundo

Cerca de 1,3 millones son las muertes que se registran cada año alrededor del mundo; y entre 20 y 50 millones de personas sufren algún tipo de traumatismo no mortal, por lo que estos accidentes representan una de las principales causas de muerte de la población entre 15 y 29 años. A continuación, se muestran datos de las últimas estadísticas sanitarias mundiales de la OMS y el informe acerca de la situación mundial de la seguridad vial. En este informe publicado por la OMS en el año 2015, se concluye que uno de los principales problemas de la salud pública sigue siendo los traumatismos que generan los accidentes de tránsito (Organización Mundial de la Salud, 2015).

- A nivel mundial uno de los principales problemas de salud pública son los traumatismos generados por los accidentes de tránsito. Son 1.3 millones de personas las que mueren alrededor del mundo cada año, representando un 93% los países de ingresos bajos y medios.
- Los conocidos como “usuarios vulnerables de la vía pública” (ciclistas, peatones y conductores o pasajeros de vehículos de transporte de dos y tres ruedas) representan la mitad de todas las muertes por accidente de tránsito a nivel mundial.
- Los traumatismos por accidentes de tránsito se reducen al realizar un correcto control de la velocidad. Son solo 47 países (13% de la población mundial) los que tienen leyes estrictas sobre velocidad en las zonas urbanas. Conforme aumenta la velocidad, aumenta la probabilidad de un accidente de tránsito, y es que con tan solo aumentar 1km/h la velocidad media esto representa un aumento del 3% en la incidencia de traumatismos y un 4 a 5% en la incidencia de muerte, todos ocasionados por los accidentes de tránsito.
- Las normas de seguridad básicas que deben tener los vehículos no se cumplen en el 80% de los países. Esto se presenta principalmente en los países de bajos o medios ingresos, produciéndose cerca de la mitad de vehículos nuevos a nivel mundial en el año 2014. Además, se presentan siete reglamentaciones importantes de seguridad de los vehículos; sin embargo, estas solo han sido adoptadas en su totalidad por 40 países dentro de los cuales 35 de ellos pertenecen a países de altos ingresos.

El grupo de personas que conforman los peatones, motociclistas y ciclistas (grupo más vulnerable) en un accidente de tránsito representan el 22%, 23% y 4% respectivamente, lo que equivale aproximadamente a la mitad referente a víctimas mortales. Es importante mencionar que este valor depende principalmente de la región, por ejemplo, Asia Sudoriental maneja índices relativamente bajos en comparación con África, (Organización Mundial de la Salud, 2015), datos que se aprecian en la Figura 1.

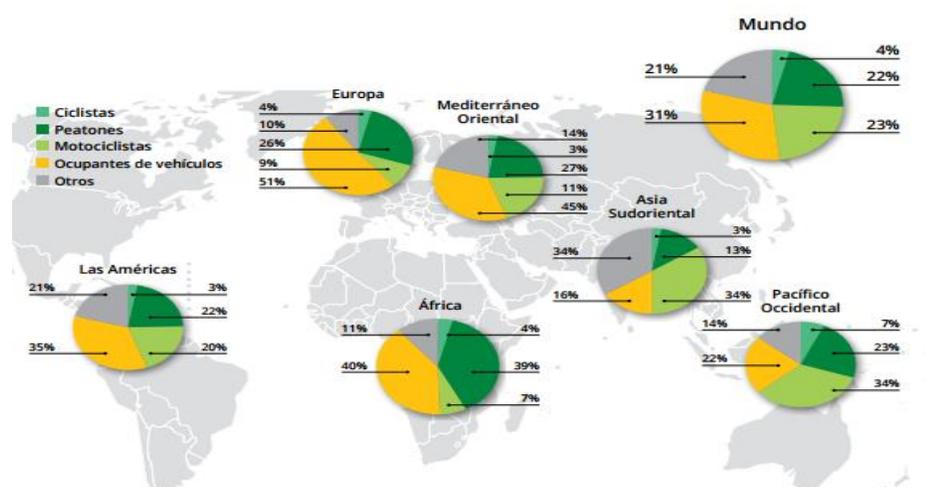


Figura 1. Muertes por accidentes de tránsito según tipo de usuario (2013)

Fuente: (Organización Mundial de la Salud, 2015)

El informe indica que es la región africana la que cuenta con la mayor tasa de mortalidad a causa de los accidentes de tránsito, y es en los países de ingresos altos entre ellos Europa, los cuales han logrado reducir de manera considerable las tasas de mortalidad. (Organización Mundial de la Salud, 2015), en la Figura 2 se presenta la tasa de mortalidad por cada 100 000 habitantes a causa de los accidentes de tránsito.

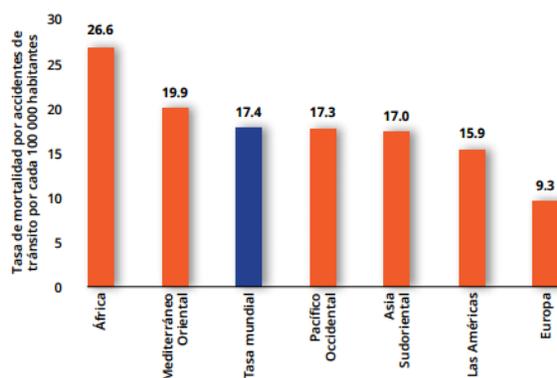


Figura 2. Tasas de mortalidad por región.

Fuente: (Organización Mundial de la Salud, 2015)

1.2.1.2 Seguridad vial en la Región de las Américas

En el informe realizado en 2013 acerca de la seguridad vial en la Región de las Américas, presenta que las defunciones a causa de un accidente de tránsito son cerca del 12% (154.089 muertes), lo cual aumento aproximadamente un 3% (149.357 muertes) en comparación al año 2010. (Organización Panamericana de la Salud, 2016)

A continuación, se presenta la distribución de muertes, la cual no es congruente con el nivel de ingresos; presentando así una mayor tasa en los países de ingresos medianos en comparación a aquellos cuyos ingresos son altos (Organización Panamericana de la Salud, 2016); véase en la Figura 3 los porcentajes de población de muertes causadas por el tránsito y vehículos motorizados registrados en la Región de las Américas por el nivel de ingresos.

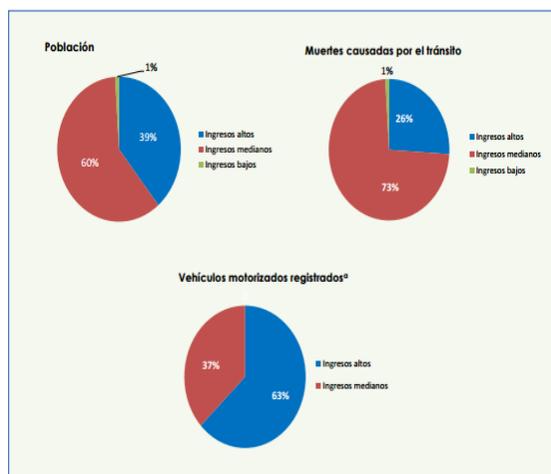


Figura 3. Porcentajes de población, 2013.

Fuente: (Organización Panamericana de la Salud, 2016)

Existen diferencias en las tasas de mortalidad dependiendo del país, representando Canadá la tasa más baja (6.0) por 100.000 habitantes, mientras que República Dominicana tiene la tasa más alta (29.3), además es alarmante dado que en aproximadamente la mitad de los países (14 países) sus tasas de mortalidad son superiores a la tasa total que representa la Región de las Américas a nivel mundial, en la Figura 4, se presenta la tasa de mortalidad en la Región.

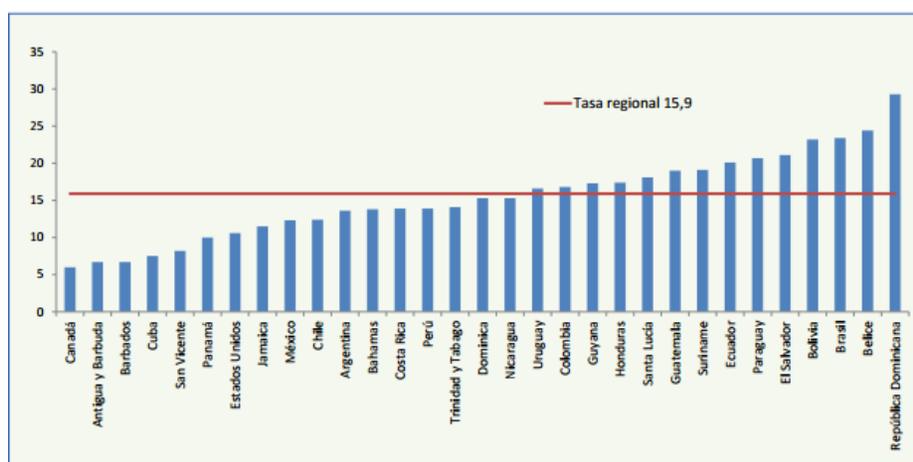


Figura 4. Tasa de mortalidad en la Región de las Américas.

Fuente: (Organización Panamericana de la Salud, 2016).

1.2.2 Accidentes de tránsito en el Ecuador

La investigación presentada por el Instituto Nacional de Estadística y Censos (INEC) recopila información de fuentes como: la Dirección General de Tránsito, la Comisión de Tránsito y Transporte Terrestre, Comisión de Tránsito del Guayas, entre otras; la cual contiene información anual acerca de los accidentes de tránsito y sus víctimas, además de la cantidad de vehículos motorizados que se encuentran matriculados y el transporte aéreo, marítimo y ferroviario, presentando su última actualización en el año 2016. (Instituto Nacional de Estadística y Censos, 2016)

Según la Agencia Nacional de Tránsito (ANT) un accidente de tránsito es un suceso eventual que ocurre en las vías, ocasionando traumatismos, lesiones, muertes, daños materiales en los cuales se encuentran involucrados usuarios de la vía, vehículos y/o entorno. (Agencia Nacional de Tránsito, 2016).

Las principales clases de accidentes de tránsito son: los choques, pérdida de pista, volcamientos, atropellos, etc.; y las principales causas son: las imprudencias que cometen muchos de los conductores, el exceso de velocidad, el no respetar las señales de tránsito, distracción, embriaguez o que haya consumido algún otro tipo de droga, invasión de carril, cometer errores al rebasar, imprudencia de los usuarios viales más vulnerables (peatón, ciclista y motociclista), entre otras (Anuario de transporte, 2016). En la Figura 5 se presenta el número de vehículos motorizados matriculados (en millones), en el periodo 2008-2015.

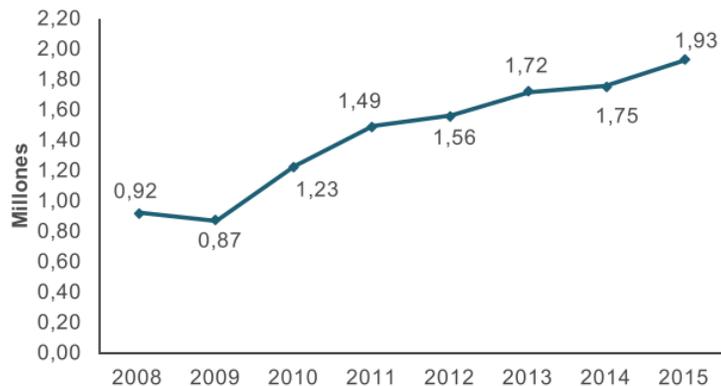


Figura 5. Número de vehículos matriculados, 2008-2015.

Fuente: (INEC, s.f.)

El número de accidentes de tránsito en el período 2008-2016 se presentan en la **Figura 6**, observándose que en comparación al año 2015, en el año 2016 la tasa disminuyó en un 15,2%.

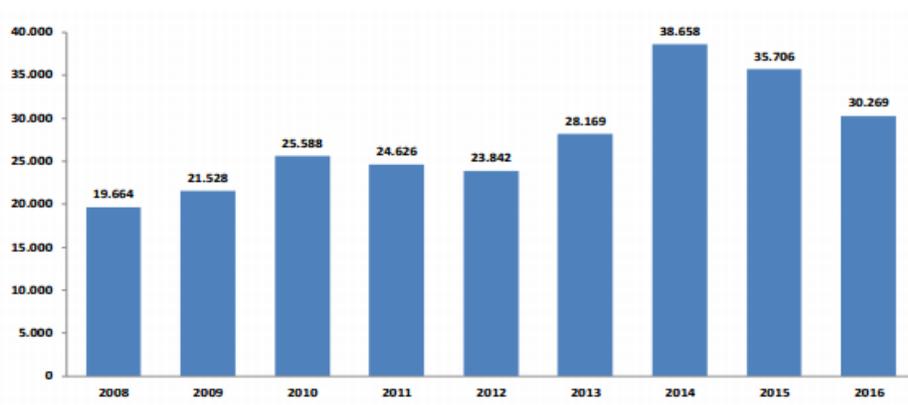


Figura 6. Número de accidentes de tránsito en Ecuador, 2008-2016.

Fuente: (Agencia Nacional de Tránsito, 2008-2016).

En el año 2016, fueron las provincias de Pichincha y Guayas las que presentaron la mayor tasa referente a accidentes de tránsito con un 35,6% y 26,1% respectivamente. (Véase Figura 7)

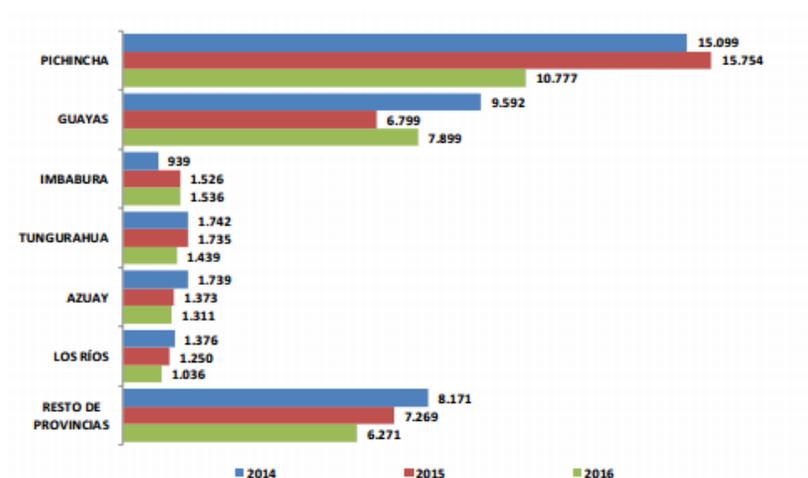


Figura 7. Accidentes de tránsito según la provincia, 2014-2016.

Fuente: (Agencia Nacional de Tránsito, 2014-2016).

Se registraron 2.522 accidentes mensuales en el año 2016, en la Figura 8 se observa que es enero el mes con mayor número de accidentes.

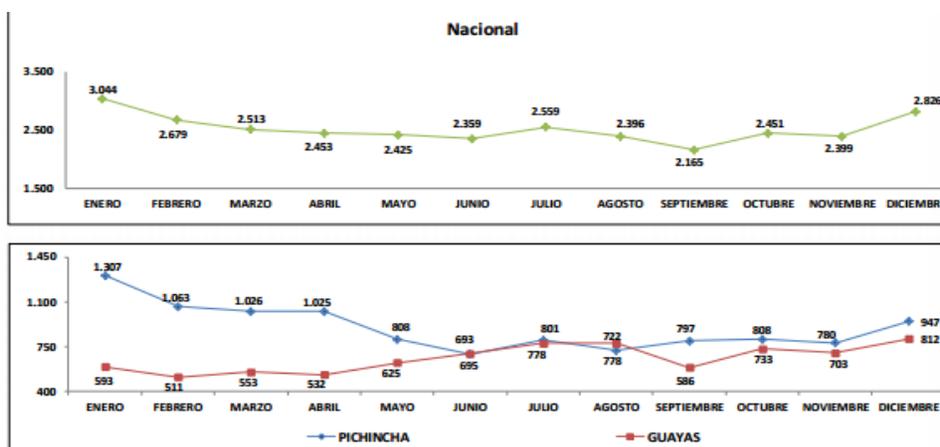


Figura 8. Número de accidentes de tránsito, por meses, año 2016.

Fuente: (Agencia Nacional de Tránsito, 2016).

Los atropellos, choques y estrellamientos representan el 75,5% del total de accidentes de tránsito registrados en el año 2016, la distribución de estos accidentes según su clase se puede observar en la Figura 9; en la categoría correspondiente a “otros” se encuentran los registros de los cuales no se obtuvo información.

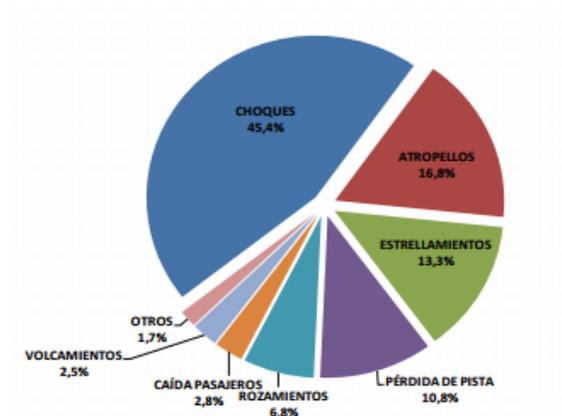


Figura 9. Distribución según su clase.

Fuente: (Agencia Nacional de Tránsito, 2016).

En el año 2016, se presentó que la principal causa de accidentes de tránsito se debe a la imprudencia del conductor con un porcentaje del 51,9% del total, en la Figura 10 se presentan los porcentajes de las principales causas de accidentes; en la categoría “otros” se incluyen los derrumbes, inundaciones, exceso de carga, explosión de neumáticos, caída de un puente, etc.

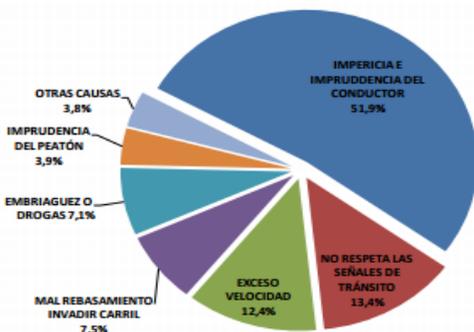


Figura 10. Distribución en base a la causa.

Fuente: (Agencia Nacional de Tránsito, 2016).

En la Figura 11, se presenta el porcentaje de heridos debido a las diferentes causas de los accidentes de tránsito en el año 2016, generando como resultado que la imprudencia del conductor es la que representa un mayor número de heridos cerca del 46% de un total de 21.458; en la categoría “otros” se incluyen los cambios climáticos, explosión de neumáticos, mal estado de la vía, derrumbe, inundación.

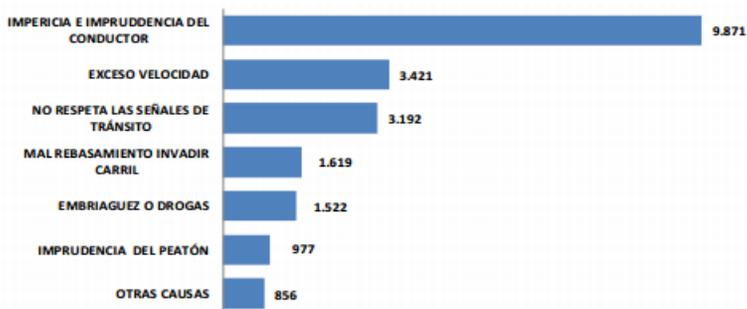


Figura 11. Número de heridos en base a la causa.

Fuente: (Agencia Nacional de Tránsito, 2016).

En la Figura 12, se presenta el número de muertos en los accidentes de tránsito, presentando nuevamente que la imprudencia del conductor es la que tiene la mayor tasa con un 56,3% del total nacional de 1967; en la categoría “otros” se incluyen los factores mencionados anteriormente.

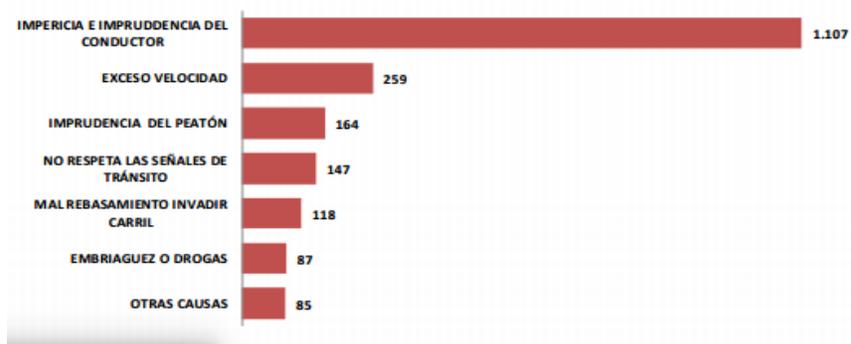


Figura 12. Número de muertos en base a la causa, año 2016.

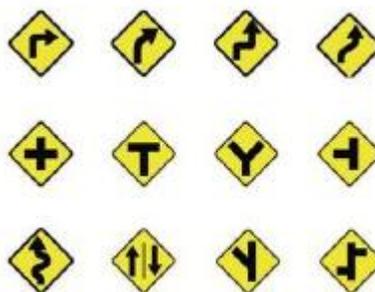
Fuente: (Agencia Nacional de Tránsito, 2016).

1.3 Tipos de señales de tránsito en el Ecuador

Las señales de tránsito presentes en la vía se clasifican según su color en reglamentarias o prohibitivas (color rojo), preventivas (color amarillo) e informativas (colores verde y azul), ver Figura 13. Para este trabajo de investigación se utilizó las señales preventivas y reglamentarias.



(a)



(b)

CONTINÚA

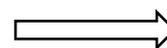




Figura 13. Principales señales de tránsito del Ecuador.

Fuente: (Agencia Nacional de Tránsito, 2016)

Nota: (a) reglamentarias, (b) preventivas, (c) informativas de servicios, (d) informativas de destinos, turismo, riesgo.

Las señales de tránsito según sus funciones se clasifican en (INEN, 2011):

- **Señales reglamentarias o prohibitivas:** Regulan el movimiento del tránsito e indican cuando se aplica un requerimiento legal, la falta del cumplimiento de sus instrucciones constituye una infracción de tránsito.
- **Señales preventivas:** Advierten a los usuarios viales, sobre condiciones inesperadas o peligrosas en la vía o sectores adyacentes a la misma.
- **Señales de información:** Informan a los usuarios de la vía de las direcciones, distancias, rutas, ubicación de servicios y puntos de interés turístico.

Es importante que las señales de tránsito presenten uniformidad en su diseño, para facilitar la identificación por parte de los usuarios viales. Por lo tanto, se estandariza el uso de la forma, color y mensaje.

1.3.1 Normalización de señales de tránsito por color

Los colores normalizados para señales se presentan a continuación y deben cumplir con las especificaciones de las normas INEN o en su defecto con las de norma ASTM D 4956. (INEN, 2011)

- **ROJO:** Se usa como color de fondo en las señales de PARE, en señales relacionadas con movimientos de flujo prohibidos y reducción de velocidad, en señales especiales de peligro, como un color de leyenda en señales de prohibición de estacionamiento, como color de borde en señales de CEDA EL PASO, triángulo preventivo y PROHIBIDO EL PASO en caso de riesgos.
- **AMARILLO:** Se usa como color de fondo para señales preventivas, señales complementarias de velocidad, distancias y leyendas, señales de riesgo, además en señales especiales delineadoras.
- **NEGRO:** Se usa como color de símbolos, leyendas y flechas para señales que tienen fondo blanco, amarillo, verde limón y naranja, en marcas de peligro, además se utiliza para leyenda en señales de direccionamiento de vías.
- **BLANCO:** Se usa como color de fondo para la mayoría de señales regulatorias, delineadores de rutas, nomenclatura de calles y señales informativas, y en señales que tienen fondo verde, azul, negro, rojo o café, como un color de leyendas, símbolos como flechas.

- **NARANJA:** Se usa como color de fondo para señales de trabajos temporales en las vías y para banderolas de CRUCES DE NIÑOS.
- **VERDE:** Se usa como color de fondo para las señales informativas de destino, peajes, control de pesos y riesgo.
- **AZUL:** Se usa como color de fondo para las señales informativas de servicio; también como color de leyenda y en señales de estacionamiento en zonas tarifadas.
- **CAFÉ:** Se usa como color de fondo para señales informativas turísticas y ambientales.

1.3.2 Normalización de señales de tránsito por forma

Las formas normalizadas para señales se presentan a continuación y deben cumplir con las especificaciones de las normas INEN o en su defecto con las de norma ASTM D 4956. (INEN, 2011)



El octógono se usa únicamente para la señal de PARE



El triángulo equilátero se usa únicamente para la señal de CEDA EL PASO.



El rectángulo se usa por lo general para señales regulatorias.



El círculo se usa para señales en los cruces de ferrocarril.



El rombo se usa para señales preventivas y trabajos en la vía con pictogramas.



La cruz diagonal amarilla se reserva exclusivamente para indicar la ubicación de un cruce de ferrocarril a nivel.



El rectángulo con el eje mayor horizontal se usa para señales de información y guía; señales para obras en las vías y propósitos especiales, así como placas complementarias para señales regulatorias y preventivas.



El escudo se usa para señalar las rutas.



El pentágono se usa para señales en zona escolar.

1.4 Sistemas inteligentes de transporte

Los avances tecnológicos han incursionado soluciones a diversos problemas en diferentes áreas, y el sector de transporte no ha quedado de lado, para lo cual surgen los sistemas inteligentes de transporte, que ofrecen medios de control, transmisión y procesamiento de información a través de los cuales permiten mejorar la movilidad, la seguridad y la productividad en el transporte optimizando la utilización de las infraestructuras existentes, aumentando la eficiencia en el consumo de energía y mejorando la capacidad de sus sistemas, y así aprovechar al máximo los recursos disponibles para que los usuarios dispongan de las herramientas y datos suficientes que faciliten el desplazamientos en los medios de transporte.

Estos sistemas obtienen la información de los diferentes elementos de interés de las carreteras, que una vez procesada y analizada, brindan varios beneficios en diferentes áreas como son: seguridad, eficiencia y ayuda al medio ambiente, logrando una considerable reducción en la tasa de accidentes, tiempos y costos, también permiten disminuir la emisión de sustancias contaminantes y el consumo de combustible, logrando disponer de sistemas de gestión del transporte eficientes, seguros y respetuosos con el medio ambiente.

Tanto la tecnología como las aplicaciones de los sistemas inteligentes de transportes es muy variada, entre ellas tenemos sistemas de gestión como los que se encargan de la navegación en los coches, los sistemas de control de las señales de tráfico, señales de mensaje variable, reconocimiento automático de placas de matrícula, cámaras de alta velocidad para monitorización, y varios más que contienen sistemas de control con cierta inteligencia en el proceso.

Dentro de las aplicaciones de sistemas inteligentes de transporte están aquellas que recopilan datos en tiempo real como información del tiempo, del estado de las carreteras y del estado del tráfico; sistemas de guía para el aparcamiento, o cualquier otro sistema del coche que requiera de la toma de decisiones a partir de la lectura de datos. En el futuro los sistemas tendrán la capacidad de adaptarse a un histórico y tomar decisiones que entren dentro de lo que se puede considerar técnicas predictivas.

1.5 Justificación e importancia

Los accidentes de tránsito son un problema que ha ido creciendo día a día en el Ecuador pues la imprudencia de los conductores al volante ha provocado pérdidas irreparables, según la Agencia Nacional de Tránsito del Ecuador con datos de enero- septiembre de 2016 se produjeron diversos accidentes de tránsito en los tres indicadores (siniestros, fallecidos y lesionados) por la impericia e imprudencia del conductor; para accidentes de tránsito siniestros las principales causas son: conducir desatento a las señales de tránsito (celular, pantallas de video, comida, maquillaje o cualquier otro elemento distractor), conducir vehículo superando los límites máximos de velocidad, no respetar las señales reglamentarias de tránsito (pare, ceda el paso, luz roja del semáforo, etc.) con un 21.60%, 12.32% y 12.14 % de ocurrencia, respectivamente (Agencia Nacional de Tránsito

del Ecuador, 2016). A continuación, se presenta los siniestros de tránsito a nivel nacional en zonas urbanas y rurales ver **Figura 14**, y los tipos de vehículos involucrados en estos accidentes ver **Figura 15** (*Otros incluye: tráiler, especial (transporte de valores, grúa, etc.), volqueta, furgoneta y tanqueros).

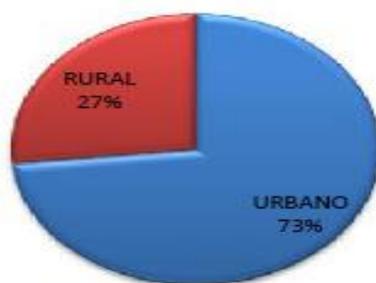


Figura 14. Siniestros de tránsito.

Fuente: DNCTSV, CTE, EMOV – Cuenca, Gobierno Autónomo Descentralizado Municipal de Loja, Gobierno Autónomo Descentralizado de Manta, Municipio de Ambato, Municipio de Ibarra, Autoridad de Tránsito Municipal de Guayaquil y Agencia Metropolitana de Tránsito de Quito.

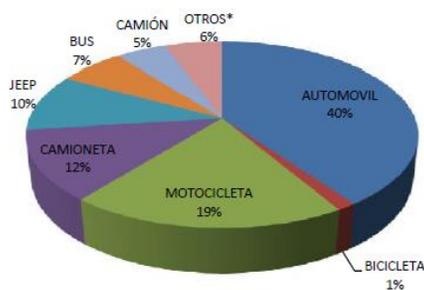


Figura 15. Vehículos involucrados.

Fuente: DNCTSV, CTE, EMOV – Cuenca, Gobierno Autónomo Descentralizado Municipal de Loja, Gobierno Autónomo Descentralizado de Manta, Municipio de Ambato, Municipio de Ibarra.

Para el segundo indicador sobre fallecimientos en accidentes de tránsito de enero - septiembre de 2016 se tiene que las principales causas son: conducir desatento a las condiciones de tránsito

(celular, pantallas de video, comida, maquillaje o cualquier otro elemento distractor), conducir vehículo superando los límites máximos de velocidad, no ceder el derecho de vía o preferencia de paso al peatón, no transitar por las aceras o zonas de seguridad destinadas para el efecto, no respetar las señales reglamentarias de tránsito (pare, ceda el paso, luz roja del semáforo, etc.), con un 38,83 %, 13.34%, 6.88%, 6.53% y 5.69% de ocurrencia respectivamente (Ecuador, Agencia Nacional de Tránsito del Ecuador, «Fallecidos Septiembre 2016,, 2016). Para el tercer indicador sobre lesionados en accidentes de tránsito de enero – septiembre 2016, las principales causas son: conducir desatento a las condiciones de tránsito (celular, pantallas de video, comida, maquillaje o cualquier otro elemento distractor), conducir vehículo superando los límites máximos de velocidad, no respetar las señales reglamentarias de tránsito (pare, ceda el paso, luz roja del semáforo, etc.), con un 21,34 %, 16.04 % y 13.65%, de ocurrencia respectivamente (Ecuador, Agencia Nacional de Tránsito del Ecuador, Lesionados Septiembre 2016, 2016). A continuación, se presenta los fallecimientos y personas lesionadas en accidentes de tránsito a nivel nacional en zonas urbanas y rurales ver **Figura 16** y **Figura 17**, y los tipos de vehículos involucrados en estos accidentes ver **Figura 18**.

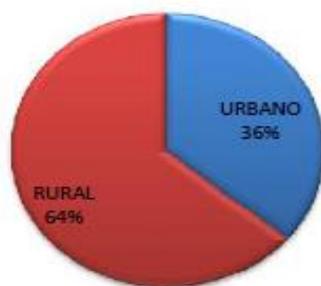


Figura 16. Fallecidos.

Fuente: DNCTSV, CTE, EMOV – Cuenca, Gobierno Autónomo Descentralizado Municipal de Loja, Agencia Metropolitana de Tránsito – Quito, Gobierno Autónomo Descentralizado de Manta, Municipio de Ambato, Municipio de Ibarra, Autoridad de Tránsito Municipal de Guayaquil.

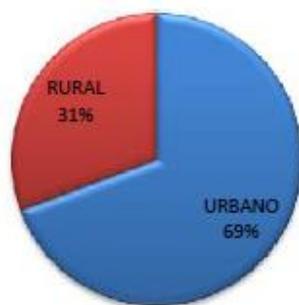


Figura 17. Lesionados.

Fuente: DNCTSV, CTE, EMOV – Cuenca, Gobierno Autónomo Descentralizado Municipal de Loja, Gobierno Autónomo Descentralizado de Manta, Municipio de Ambato, Municipio de Ibarra, Autoridad de Tránsito Municipal de Guayaquil y Agencia Metropolitana de Tránsito de Quito.

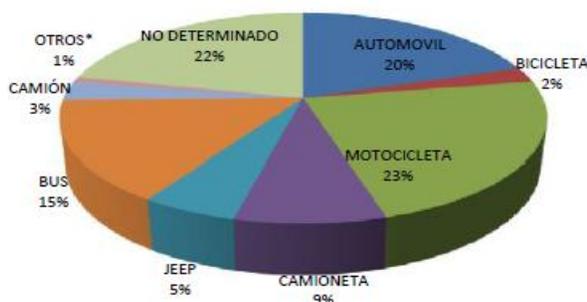


Figura 18. Lesionados, tipo de vehículos.

Fuente: DNCTSV, CTE, EMOV – Cuenca, Gobierno Autónomo Descentralizado Municipal de Loja, Gobierno Autónomo Descentralizado de Manta, Municipio de Ambato, Municipio de Ibarra, Autoridad de Tránsito Municipal de Guayaquil y Agencia Metropolitana de Tránsito de Quito.

1.6 Alcance del proyecto

En el presente trabajo de investigación, se desarrolla un algoritmo automático de detección de señales de tránsito, utilizando técnicas de visión por computadora. El proyecto se enfoca en las señales de tránsito preventivas y reglamentarias del Ecuador.

En la primera etapa del proyecto se desarrolla dos algoritmos. El primero se enfoca en la clasificación de píxeles usando color para generar candidatos a señales de tránsito (ROIs). El segundo se enfoca en la construcción de una nueva arquitectura de aprendizaje profundo para la clasificar las ROIs generadas en la etapa anterior.

Para la etapa de clasificación usando color, se trabaja con los colores: rojo y amarillo, para ello se construye un nuevo modelo en color para segmentar las imágenes, y generar una lista de posibles candidatos denominados regiones de interés (ROI), bajo condiciones de iluminación variable, en el espectro visible.

Para la etapa de clasificación y reconocimiento de imágenes, se utiliza la una Red Convolutiva Rápida (Fast R-CNN) que forma parte del Aprendizaje Profundo (Deep Learning), generando una nueva arquitectura para la clasificación de las señales de tránsito.

En la segunda etapa, se realiza la integración de los algoritmos de generación de ROIs y de clasificación de señales de tránsito, para construir un algoritmo de detección, especializado en las señales de tránsito preventivas y reglamentarias.

Finalmente, utilizando una cámara para la captura de imágenes, una unidad de procesamiento gráfico (GPU) para procesar la información visual se genera un sistema de detección de señales de tránsito.

1.7 Objetivos

1.7.1 Objetivo general

- Desarrollar un algoritmo para la detección automática de señales de tránsito prohibitivas y reglamentarias del Ecuador utilizando una red convolucional rápida.

1.7.2 Objetivos específicos

- Elaborar un algoritmo para la segmentación automática mediante color de las señales de tránsito reglamentarias y prohibitivas del Ecuador.
- Elaborar un algoritmo para la clasificación automática de señales de tránsito reglamentarias y prohibitivas usando una red convolucional rápida.
- Implementar un algoritmo de detección y reconocimiento de señales de tránsito reglamentarias y prohibitivas del Ecuador.
- Medir la eficiencia del sistema mediante curvas ROC para la clasificación, y curva tasa de error versus FPPI para la detección.

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 generación de ROIs y para la etapa de clasificación.

El capítulo 3 describe el algoritmo desarrollado para la clasificación de píxeles usando color; para lo cual se utiliza el algoritmo de clasificación K-NN con k-means para segmentar los colores de interés; posteriormente se realiza una mejora de la segmentación usando un filtro en el espacio de color HSV, obteniendo finalmente las regiones interés ROIs.

En el capítulo 4 se presenta el algoritmo de clasificación de señales de tránsito preventivas y reglamentarias utilizando una red convolucional rápida. En este capítulo se detalla el proceso de entrenamiento y evaluación para la obtención de una nueva arquitectura.

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 variables.

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

Una de las principales razones para que los trabajos relacionados a la detección automática de señales de tránsito se desarrollen ha sido el avance de la tecnología, es por esto que en los últimos años se ha logrado observar el avance de los sistemas ADAS (Sistemas avanzado de asistencia a la conducción), con la finalidad de asistir al conductor y reducir el número de accidentes en la vía (Cruzado Hernando , 2015).

Los trabajos de detección automática de señales de tránsito, sugieren que para una buena detección automática de la señal se lleve a cabo el proceso en dos etapas; la primera que corresponde a la detección de la ubicación de la señal en la imagen, en otras palabras generar las regiones de interés (ROIs), mientras que la segunda etapa conocida como clasificación consiste en el reconocimiento de la señal (Hatzidimos, 2004) y (Zeng, Xu, Fang, & Zhao, 2015).

2.2 Detección de señales de tránsito

El proceso de segmentación es fundamental en el procesamiento de imágenes; siendo necesario principalmente cuando se desea analizar solamente una determinada región de la imagen, la cual toma el nombre de Región de Interés (ROI) (Rocha & Escorcía , 2010), (Villalón, Torres, & Flores-Calero, Sistema de detección de señales de tráfico para la localización de intersecciones viales y frenado anticipado, 2017) y (Cruzado Hernando , 2015).

La detección de una región de interés presenta algunas dificultades al momento de segmentar una imagen (Rocha & Escorcía , 2010), (Carbajo Benito, 2015), (Villalón, Torres, & Flores-Calero, Sistema de detección de señales de tráfico para la localización de intersecciones viales y frenado anticipado, 2017) y (Yang, Liu, & Huang , 2003) dentro de ellas se puede mencionar: problemas en la adquisición reflejándose en ruido en la imagen; que los objetos no posean una iluminación uniforme; otro problema es la forma de los objetos, presentando en muchas ocasiones similitudes en los mismos; además se puede presentar ruido generando imágenes de baja calidad.

La detección de señales de tránsito ha ganado gran interés en las últimas dos décadas, y para ello se han presentado varios enfoques. Dichos enfoques se centran en la segmentación basada en color y forma de las señales de tránsito (Li, Sun, Liu, & Wang, 2015). A continuación, se presentan los principales aportes basados en los dos enfoques previamente mencionados

2.2.1 Segmentación a través del color

El estudio realizado por (Gómez Moreno, Maldonado Bascón, Gil Jiménez, & Lafuente Arroyo, 2010) clasifica los métodos de segmentación en umbrales de espacio de color, detección de bordes y la descomposición cromática/acromática. Dentro de su investigación concluyen que los mejores métodos son aquellos en los cuales se trabaja con espacios de color como RGB (Red, Green, Blue) normalizados; mientras que (Zaklouta & Stanciulescu, 2014) utilizan el espacio RGB para las señales preventivas y reglamentarias, colores amarillo y rojo respectivamente; en esta literatura presentan un filtro cromático.

Existen otras literaturas que prefieren usar para la segmentación en base a color umbrales en el espacio HSV (Brillo, Saturación, Valor), ya que lo consideran más intuitivo que los demás,

permitiendo depender menos del brillo o de las sombras presentadas en la imagen. En (Arriagada García & Aracena Pizarro, 2007) realizan un estudio utilizando este espacio, generando los rangos en los que varían los colores, obteniendo de esta manera un valor máximo y mínimo para que un píxel sea considerado de un color específico; posteriormente investigan el área, con la finalidad de discriminar una región de interés por su tamaño; al unir estos dos procedimientos se reduce notablemente el tiempo de ejecución.

Existen otros autores como (Franke, y otros, 1999), (Villalón, Torres, & Flores-Calero, Sistema de detección de señales de tráfico para la localización de intersecciones viales y frenado anticipado, 2017) y (Zaklouta & Stanciulescu, 2014) los cuales utilizan el espacio de color RGB en la segmentación, a pesar de que uno de los principales problemas de este espacio de color se presenta por las variaciones de iluminación, debido a que es muy sensible.

El espacio de color CIELab fue utilizado por (Lopez & Fuentes, 2007), quienes modelaron los píxeles de color con el modelo gaussiano con la finalidad de reducir el efecto que tiene la iluminación en la imagen.

2.2.2 Segmentación a través de la forma

A pesar de que la segmentación a través del color tiene un buen comportamiento, aún presenta algunos inconvenientes para algunos ambientes; es por esto que para eliminar en cierta proporción este problema se utilizan métodos basados en contornos; a continuación, se presentan algunos ejemplos:

En (Damavandi & Mohammadi, 2004) utilizan la transformada de Hough para detectar las señales de límite de velocidad, sin embargo este método presenta una gran complejidad computacional; con la finalidad de reducir dicha complejidad (Barnes & Zelinsky, 2008) mejoraron el proceso proponiendo un detector de simetría radial rápido logrando así detectar las señales de velocidad circulares.

El trabajo realizado por (Yang, Liu, & Huang, 2013) realiza la segmentación definiendo un rango para el color rojo, para posteriormente identificar los bordes de las señales triangulares usando un algoritmo de detección de esquinas.

En (Maldonado, 2007) para la generación de ROIs utilizan un umbral en el espacio de color HSV, posteriormente dentro de las ROIs generadas utilizan la característica de distancia al borde (DtB), para finalizar con un clasificador SVM (Support Vector Machine).

En la investigación realizada por (Khan, Bhuiyan, & Adhami, 2011) utilizan el espacio de color CIELab; posteriormente implementan el método de agrupamiento conocido como K-Means (Berzal, s.f.) para dividir la imagen en varias regiones y las características DtB y Peri2Area o P2A (perímetro de la ROI al cuadrado sobre el área de la misma), con la finalidad de distinguir las formas

(Pankaj & Patil, 2013) presentan un sistema que consta de tres etapas: la primera consiste en la segmentación utilizando para ayuda de la misma el método de agrupamiento K-Means (Berzal, s.f.), realizando la agrupación de píxeles en base a su color con la finalidad de generar las respectivas ROIs, la segunda etapa consta de la implementación de dos criterios para la detección

de formas, estas son P2A y punto de contacto límite y finalmente utilizan el coeficiente de correlación para el reconocimiento del símbolo de la señal.

CAPÍTULO III

3. CLASIFICACIÓN DE PÍXELES USANDO COLOR

3.1 Introducción

En el presente capítulo se presenta el método de extracción de ROIs para posteriormente ser enviadas a la etapa de clasificación para el reconocimiento de la señal de tránsito. Antes de ingresar a la etapa de clasificación se realiza un pre-procesamiento de la imagen de entrada con la finalidad de mejorar características de la misma; dicha imagen ya mejorada es enviada a la etapa de clasificación de píxeles la cual presenta diferentes sub-etapas; la primera de ellas consiste en la segmentación usando color por ser una de las características más relevantes de las señales de tránsito preventivas y reglamentarias, para ello se utiliza el algoritmo de clasificación $k - NN$ con $k - means$; finalmente se realiza un pos-procesamiento con la finalidad de eliminar aquellas ROIs que no cumplan con determinadas características de una señal de tránsito. La Figura 19 muestra en esquema lo expuesto anteriormente para la etapa de clasificación de píxeles usando color.

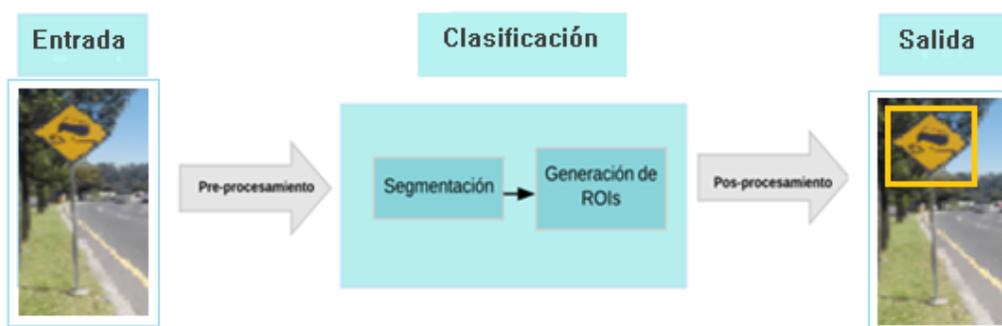


Figura 19. Esquema propuesto para localizaciones de candidatos.

3.2 Sub-etapa de pre-procesamiento

Debido a los constantes cambios de iluminación los cuales representan un problema en proyectos de visión artificial, en (Conlago Guatemal & Yunda Sangoluisa, 2016) se realiza un estudio de los diferentes espacios de color, con el objetivo de determinar cuál presenta una mayor robustez; generando como resultado que para ambientes de iluminación en condiciones ambientales correspondientes a días normales, soleados y nublados el espacio de color que presenta una distribución más uniforme es el RGB Normalizado en los canales Gn y Bn; por lo tanto será este el espacio utilizado para el presente trabajo.

A continuación, en la Figura 20 se presenta la distribución de las muestras en el espacio de color seleccionado para los colores de interés para el color rojo el número de muestras utilizadas es de 270000 para el color amarillo de 300000 y para el resto de colores es de 330000.

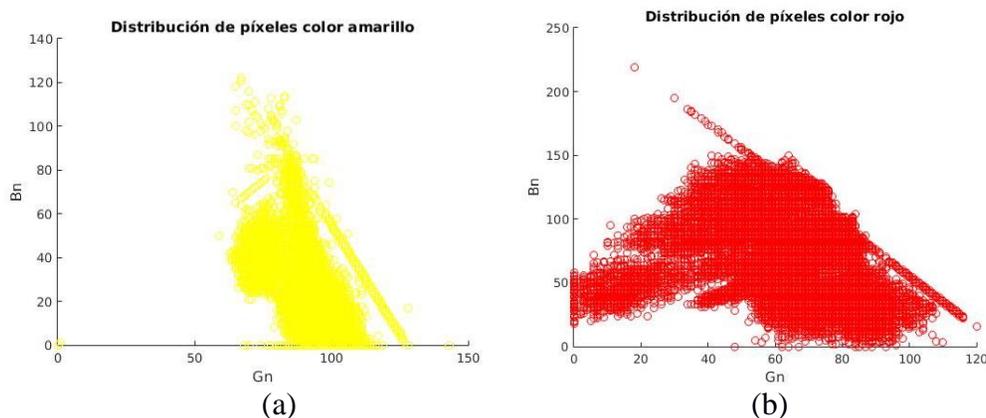


Figura 20. Distribución de píxeles espacio de color RGB normalizado.

Nota: (a) amarillo y (b) rojo.

3.2.1 Ecuación de histograma de la imagen

El pre-procesamiento se realiza con la finalidad de normalizar el brillo y mejorar el contraste de la imagen de entrada, para posteriormente ser enviada a la etapa de detección.

Muchas veces no resulta sencillo emparejar los colores de una imagen, debido a los diferentes valores de intensidad; es por ello que se trabaja con el histograma (grafico de las frecuencias relativas de los niveles de intensidad) específicamente se realiza la ecualización del histograma de la imagen a color la cual genera una nueva imagen cuyos niveles de intensidad cubren todo el rango, por lo que tiende a poseer un mayor contraste y una distribución más uniforme, dado que un histograma ideal es aquel que ocupa casi todo el rango de tonos (González & Woods, 2008).

Los ecualizadores que generalmente se utilizan realizan una operación global, es decir, consideran el histograma de la imagen completa; la desventaja de este tipo de ecualización es que no considera la información local de cada píxel, por lo que se puede obtener un bajo contraste en ciertas regiones pequeñas. Con la finalidad de resolver este inconveniente se implementó la técnica CLAHE (Contrast Limited Adaptive Histogram Equalization), este método procesa la imagen por subregiones, por lo que divide a la imagen en bloques pequeños de 8x8 (Valeo, 2015) y para cada uno de ellos se ecualiza la imagen como en el ecualizador global; además de recortar picos sobresalientes en el histograma generados por la presencia de ruido y por regiones homogéneas en la imagen; por lo que esta técnica recorta una parte del pico en base a un límite de contraste especificado y redistribuye sobre todo el histograma de manera uniforme los valores recortados (Valeo, 2015), para mantener el número total de píxeles en la imagen e intacta la totalidad del histograma. En la Figura 21 se presenta el proceso de la técnica CLAHE.

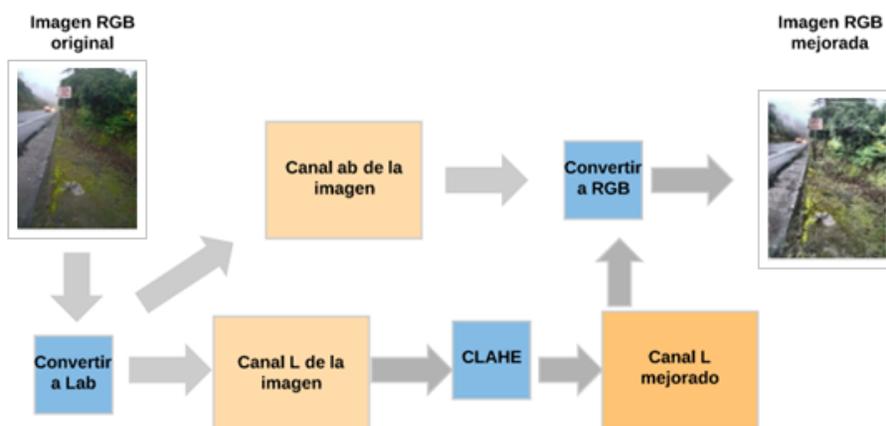


Figura 21. Esquema de la Técnica CLAHE.

En la Figura 22 se presenta la mejora de contraste con el ecualizador global, y la técnica CLAHE, aplicado a señales de tránsito amarillas y rojas utilizando el espacio CIELab; por lo que previamente se debe transformar del espacio de color RGB al espacio CIELab dado que este es uno de los espacios que separa la luminosidad (L) del color (a: rojo/verde, b: azul/amarillo).

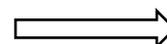


(a)



(b)

CONTINÚA





(c)



(d)



(e)



(f)

Figura 22. Mejora del contraste con los ecualizadores global y CLAHE

Nota: a) y b) Condición de iluminación día normal, c) y d) condición de iluminación día soleado, e) y f) condición de iluminación día nublado.

3.3 Segmentación multicolor usando $k - NN$ con $K_m - means$ en condiciones de iluminación variable

Para la segmentación basada en color se han diferenciado dos clases de interés que son los colores de las señales de tránsito preventivas y reglamentarias, colores amarillo y rojo respectivamente; y una clase de no interés para el resto de colores. El algoritmo de clasificación utilizado es $k - NN$ (k - Nearest Neighbors), el cual presenta una “etiqueta” la cual indica la clase a la que pertenecen los nuevos casos (pruebas), comparados con los casos ya disponibles (entrenamiento); este algoritmo utiliza la distancia euclídea para generar los resultados (Cost & Salzberg, 1993). Previamente se modela cada clase (dos de interés y una de no interés) con un conjunto de centroides, utilizando para ello el algoritmo de agrupación $Km - means$ (Lillo Castellano, 2010) y (Rojas Henríquez & Aracena Pizarro , 2013).

El proceso de aprendizaje de este clasificador consiste en almacenar en una matriz el conjunto de entrenamiento y en un vector la clase a la que pertenecen cada uno de los elementos de este conjunto. En el clasificador $k - NN$ el valor del parámetro k depende del número de ejemplos utilizados para el diseño del clasificador (Duda, Hart , & Stork, 2001) y (Arriagada Rodríguez, 2015)

Para determinar la clase a la que pertenecen los elementos de prueba, el algoritmo $k - NN$ por votación asignan la etiqueta mayoritaria correspondiente al vecino más cercano (Lillo Castellano, 2010).

El algoritmo $Km - means$, agrupa los elementos de tal forma que los objetos tengan una alta similitud entre ellos, representado por la media de sus puntos, es decir sus centroides (Lillo Castellano, 2010), (Salazar Zapata, Patiño , & Willian Branch, 2011) y (Rojas Henríquez &

Aracena Pizarro , 2013); por lo que se obtienen los determinados centroides para las dos clases de interés (color amarillo y rojo) y para la clase de no interés (otros colores).

Para la segmentación basada en color, se utilizan dos clases de interés (colores rojo y amarillo) y una clase de no interés (otros colores); a continuación en la Figura 23 se muestra la distribución de los colores rojo, amarillo (en rojo y amarillo respectivamente) y resto de colores (en azul) en las componentes Gn-Bn del espacio de color RGB normalizado.

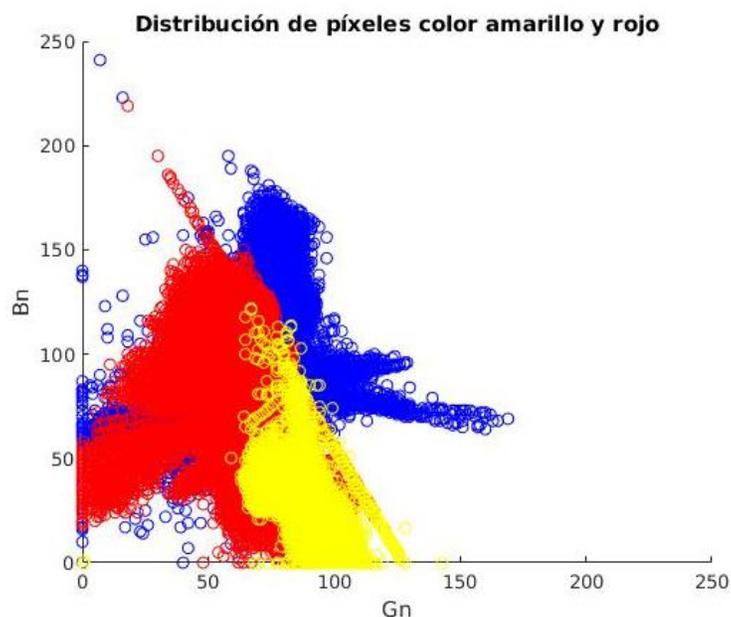


Figura 23. Distribución de los colores de interés y no interés.

El valor que se escoge para el número de centroides se lo determino mediante el método experimental; (Conlago Guatemal & Yunda Sangoluisa, 2016) realizan un análisis de diferentes métodos y seleccionan el método experimental para determinar el número óptimo de centroides.

3.3.1 Mejora de detección de píxeles usando el espacio de color HSV

Dado que los resultados obtenidos usando K-NN y el espacio de color RGB normalizado no fueron en todas las condiciones de iluminación los esperados, se aplicó un filtro adicional de los píxeles usando el espacio de color HSV (Hue Saturation Value), esta decisión se tomó en vista de que este modelo no se ve gravemente afectado por los cambios de iluminación (De La Cruz , 2017) y (Arriagada García & Aracena Pizarro, 2007), ya que cuenta con un canal específico para el color (canal H).

En base al espacio de color HSV para que un píxel sea considerado como parte de un determinado color se toman los siguientes rangos de valores, representados como $[H_{\text{mínimo}}, S_{\text{mínimo}}, V_{\text{mínimo}}]$ y $[H_{\text{máximo}}, S_{\text{máximo}}, V_{\text{máximo}}]$; para el color amarillo $[10, 76, 50]$ $[30, 255, 255]$ y para el color rojo $[0, 65, 75]$ $[10, 255, 255]$ U $[120, 65, 75]$ $[250, 255, 255]$, valores tomados en base a pruebas en las diferentes condiciones de iluminación en el espectro visible, obteniendo como resultado una imagen en la cual se han segmentado los colores que se encuentran entre los valores máximos y mínimos establecidos.

Para llevar a cabo la unión de la segmentación en base al algoritmo K-NN y el filtro basado en el espacio de color HSV se utiliza la función *bitwise_or* y *bitwise_and* (Calvo J. C., 2013), la cual nos permite implementar las funciones lógicas “or” y “and” realizando una operación bit a bit entre dichas imágenes segmentadas, obteniendo así una sola imagen segmentada con mejores resultados.

3.4 Sub-etapa de post-procesamiento

En la sub-etapa de segmentación se presentan diversos problemas, los cuales se deben corregir en la medida de lo posible, entre los más comunes se tiene:

- ROIs generadas que no contienen las señales de tránsito de interés; al realizar la segmentación por color en base a las componentes Gn-Bn existen píxeles que se filtran en este rango y generan ROIs falsas, además de la similitud de color en otros objetos.
- La velocidad a la que viaja el vehículo, generando vibraciones en la adquisición del video y por ende deteriorando la calidad de la imagen.
- Deterioro, oclusiones o pegatinas en las señales de tránsito.

Tabla 1.

Parámetros de tamaño que debe cumplir una ROI

Parámetros	Valor mínimo	Valor máximo
Área	120 píxeles	5000 píxeles
Relación (w/h)	0.2	1.4
Ancho (w)	5 píxeles	84 píxeles
Alto (h)	24 píxeles	60 píxeles
Distancia	5 metros	35 metros

La etapa de pos-procesamiento se implementa con la finalidad de resolver los posibles problemas presentados en la generación de ROIs como: i) píxeles mal clasificados, ii) bordes imprecisos de determinados objetos o regiones que se solapan con otras. Para ello se utilizan los operadores morfológicos de dilatación y erosión (Aguilar Carrera, 2005), el primero para comprobar si un píxel vecino corresponde a un determinado conjunto y por ende agregar dicho

píxel al conjunto; y el segundo para eliminar píxeles vecinos que no correspondan al conjunto, eliminando así cuerpos de no interés en la imagen. Además, se aplica el operador Laplaciano (Vliet & Young , 2009), que consiste en un método para detectar bordes en la imagen. Finalmente, para eliminar falsos positivos, se establece el tamaño máximo y mínimo para las regiones de interés, tras realizar el pos-procesamiento, las regiones que no sean eliminadas se consideran potenciales candidatos a señales de tránsito, para pasar a la etapa de clasificación de la señal de tránsito; en la **Tabla 1** se presentan dichos valores los cuales fueron determinados de forma experimental.

3.5 Parámetros finales para funcionamiento de etapa de detección

Mediante el uso del método experimental para seleccionar el número de centroides se obtiene un mejor rendimiento con los siguientes valores: para la clase de color rojo un $km= 40$, para el color amarillo $km= 40$ y para el resto de colores $km= 50$.

A continuación, en la Figura 24, se presenta la distribución de los centroides del espacio de color RGB normalizado, para las clases de interés y no interés, los centroides obtenidos servirán para el entrenamiento del clasificador k-NN.

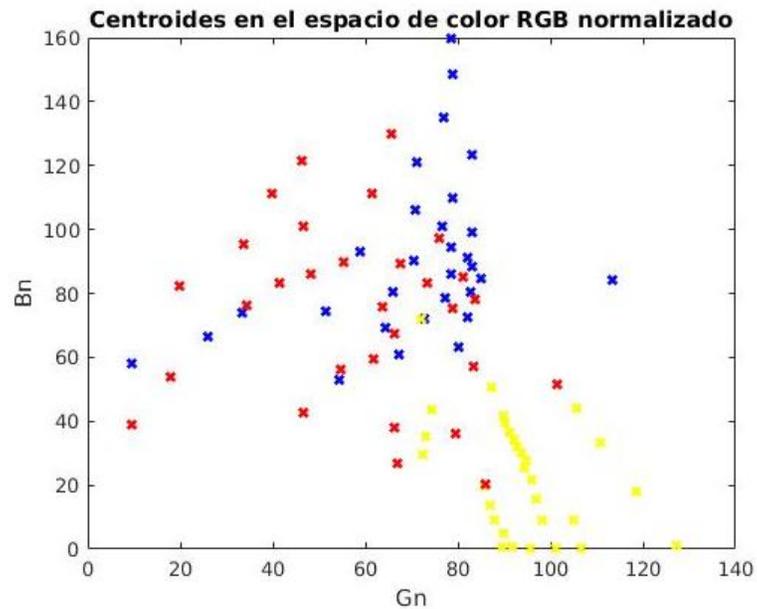


Figura 24. Distribución de los centroides para las clases de interés y no interés.

Para determinar el valor del parámetro k para el algoritmo k -NN, se realizaron pruebas explorando el rango de 1-10; para ello se considera el error generado por el clasificador al clasificar una muestra; por lo que los mejores resultados se generaron con un 3-NN. En la Figura 25 se presenta la segmentación de una señal de tránsito.



(a)

CONTINÚA

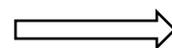




Figura 25. Segmentación de señal de tránsito.

Nota: (a) preventiva y (b) reglamentaria.

A continuación, en la Figura 26 se presentan las mejoras en la segmentación por color al aplicar filtro utilizando espacio de color HSV, para señales de tránsito.

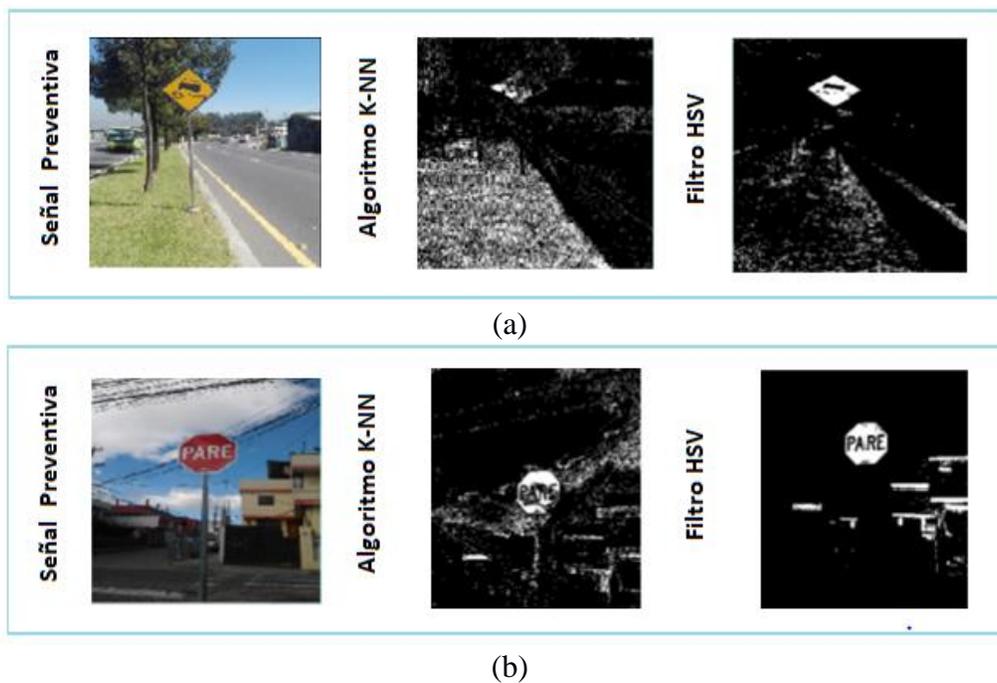
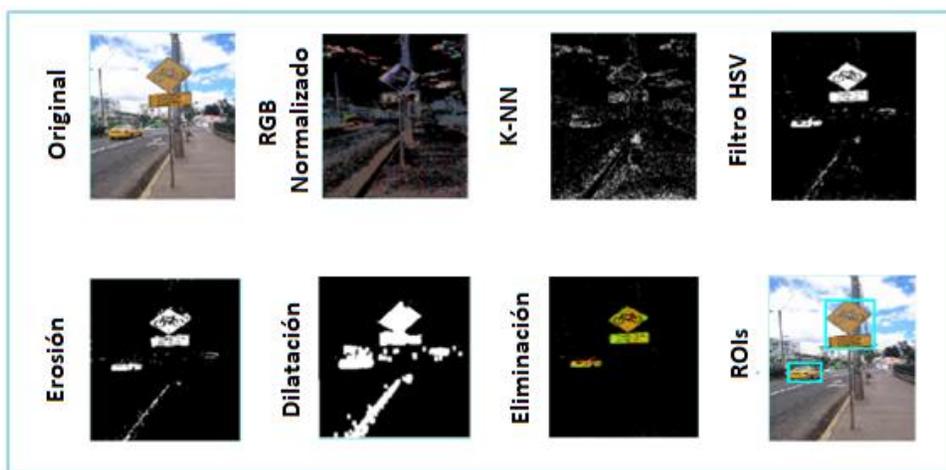


Figura 26. Segmentación mediante K-NN y filtro usando espacio de color HSV.

Nota: (a) preventiva y (b) reglamentaria.

En las Figura 27, Figura 28 y Figura 29 se presenta el proceso completo de generación de ROIs en las tres condiciones de iluminación de interés: días normales, nublados y soleados respectivamente. El proceso completo cuenta con la segmentación a través de color usando el algoritmo K-NN, para posteriormente mejorar estos resultados con el filtro usando el espacio de color HSV, además de los procesos de dilatación, erosión y eliminación de los cuerpos que no cumplen con los tamaños promedios de una señal de tránsito, obteniendo finalmente las regiones de interés (ROIs).



(a)



(b)

Figura 27. Generación de ROIs día normal.

Nota: (a) preventiva y (b) reglamentaria.



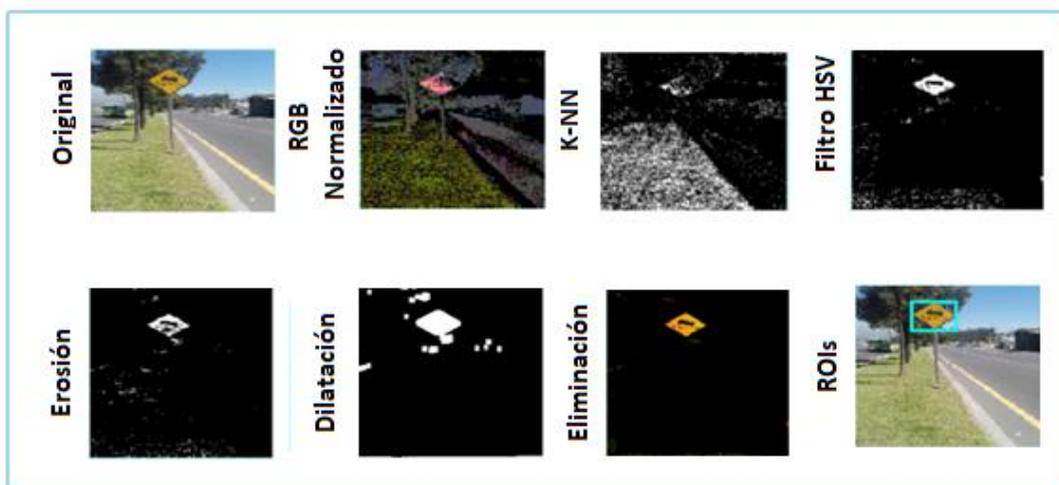
(a)



(b)

Figura 28. Generación de ROIs día nublado.

Nota: (a) preventiva y (b) reglamentaria.



(a)



(b)

Figura 29. Generación de ROIs día soleado.

Nota: (a) preventiva y (b) reglamentaria.

3.6 Generación de ROIs

La finalidad de la etapa de clasificación de píxeles usando color es generar regiones de interés (ROIs), proceso que consiste en encontrar regiones que posiblemente contengan una señal de tránsito, tomando como referencia el color (rojo y amarillo). A continuación, en la Figura 30 se observa en (a) la ROI seleccionada manualmente para una señal de tránsito preventiva (color amarillo) y en (b) las ROIs generadas en la etapa de detección, concluyendo que para este fotograma se genera una ROI que no es válida.



(a) (b)
Figura 30. Comprobación de ROIs válidas.

En la **Figura 31** se observa en (a) la ROI seleccionada manualmente de una señal de tránsito reglamentaria (color rojo) y en (b) las ROIs generadas en la etapa de detección, concluyendo que para este fotograma se generan 5 ROIs que no son válidas.



(a) (b)
Figura 31. Comprobación de ROIs válidas.

CAPÍTULO IV

4. CLASIFICACIÓN DE SEÑALES DE TRÁNSITO PREVENTIVAS Y REGLAMENTARIAS

En el presente capítulo se presenta el diseño de una nueva arquitectura usando Fast-RCNN, para la clasificación de señales de tránsito.

4.1 Redes Convolucionales

Una red convolucional la comprenden básicamente tres tipos diferentes de capas (Deshpande, s.f.) (Standford, s.f.) (Calvo D. , s.f.), sin contar las capas de entrada y de rectificación. La primera capa de la red es la Data en la cual se lee las imágenes en lotes de 50, se la redimensiona a un valor de 32x32, para pasar a las siguientes capas. La capa de convolución es la encargada de extraer las características de la imagen de entrada como líneas verticales, horizontales o diagonales, colores, o bordes, haciendo uso de diferentes filtros, y obteniendo de esta manera el mapa de características. La capa de activación se usa para evitar la no linealidad en un sistema que al salir de la capa de convolución, ha realizado operaciones lineales como sumas y multiplicaciones, para ello se utiliza la función ReLU, que a diferencia de las funciones tanh o sigmoid, permite acortar el tiempo de entrenamiento y evitar el problema de fuga de gradiente. La capa ReLU esta descrita por la ecuación (1).

$$f(x) = \max(0, x) \tag{1}$$

Después de la capa ReLU, se aplica una capa de agrupamiento la cual, resume las características más importantes de una imagen, reduciendo la resolución de esta para disminuir el costo de cálculo y controlar el sobreajuste. Para esta capa también existen varias opciones de operación como la agrupación promedio o la agrupación normal, siendo la más popular la operación max-pooling.

Las siguientes capas por implementarse son las capas completamente conectadas (FC por sus siglas en inglés), haciendo uso de una neurona para cada clase seguida de una capa ReLU.

Finalmente, en la capa de salida se aplica regresión logística, como es un problema de multclasificación se usa Softmax como clasificador. En la **Figura 32** se observa una arquitectura simple de red convolucional.

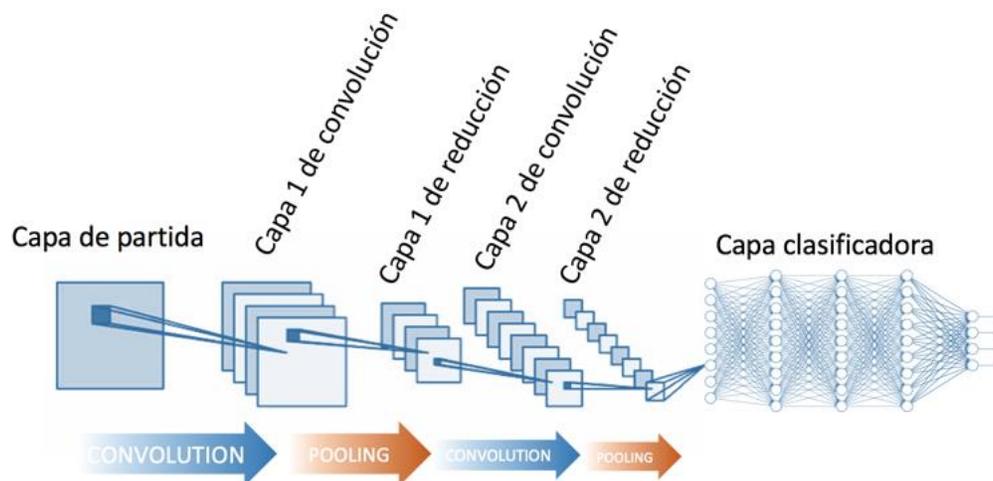


Figura 32. Ejemplo de una arquitectura simple de red convolucional

4.2 Arquitectura Fast RCNN



Figura 33. Esquema general de clasificación de señales de tránsito.

Para diseñar la arquitectura se siguieron los siguientes pasos:

- i. Tomar varias arquitecturas conocidas y entrenarlas
- ii. Obtener el mejor AUC y tomar la red correspondiente como la red base
- iii. Fijar en 30, el número de modificaciones a realizar
- iv. Tomar la red base obtenida en el paso (ii) y modificarla, añadiendo y reduciendo capas.
- v. Realizar el proceso anterior hasta obtener el mejor AUC o alcanzar el número de modificaciones máximo.

Para escoger la mejor red, se realizaron pruebas experimentales con tres arquitecturas fast R-CNN para la clasificación de señales de tránsito, la red LeNet (Y. LeCun, 1998) , la Alexnet (Alex Krizhevsky, 2012) y la GoogleNet (Christian Szegedy, 2015), obteniendo los resultados que se muestran en la **Tabla 2**

LeNet es una red pionera, fue utilizada por varios bancos en 1998, en 2012 aparece Alexnet con una arquitectura muy similar a LeNet, pero mucho más profunda, con más filtros por capa, y capas convolucionales apiladas. En el 2014 GoogleNet gana la competencia ILSVRC 2014, haciendo uso de una arquitectura inspirada en LeNet pero utilizando normalización de lotes.

Tabla 2.

Resumen del entrenamiento de Arquitecturas base para este trabajo

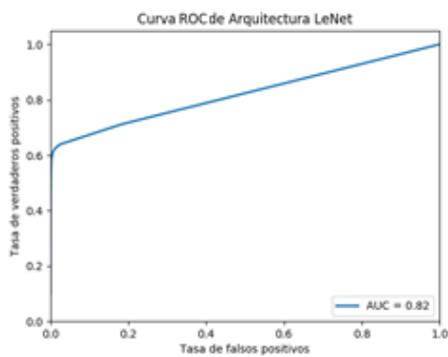
Arquitectura	Pr	PE	PEt	TE	AUC
LeNet	0,9812	0,08	0,03	202 min	0,82 Ver Figura 34
Alexnet	0.9899	0,06	0,009	225 min	0,86 Ver Figura 34
GoogleNet	0,9944	0,15	0,29	280 min	0,69 Ver Figura 34

Pr: Precisión

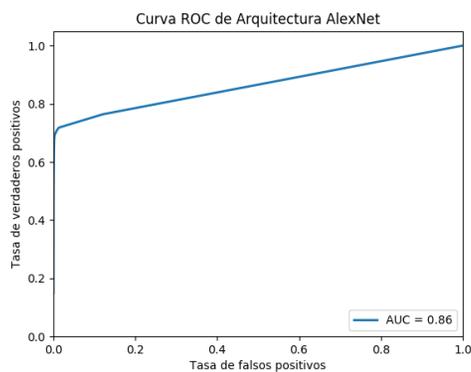
PE: Pérdida de Evaluación

PEt: Pérdida de Entrenamiento

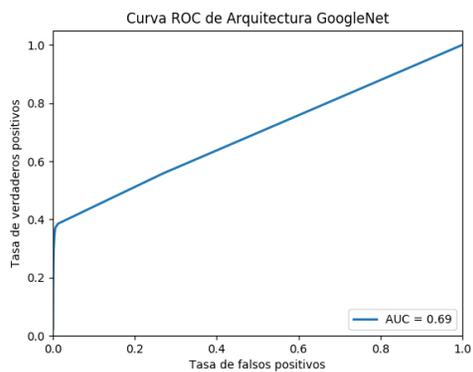
TE: Tiempo entrenamiento



(a)



(b)



(c)

Figura 34. Curvas ROC de arquitecturas base

Nota: (a) LeNet (b) Alexnet (c) GoogleNet

El mayor valor **AUC** es **0.86** y corresponde a la arquitectura Alexnet, entonces se tomará esta arquitectura como base para el diseño de una nueva arquitectura para la clasificación de señales de tránsito.

En base a esta arquitectura se realizaron variaciones en los distintos parámetros con la finalidad de comparar el rendimiento de la red al realizar estos cambios.

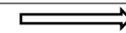
1. Aumentar capas de convolución y ReLU
2. Disminuir capas de convolución y ReLU
3. Aumentar y disminuir el tamaño de los filtros
4. Aumentar y disminuir la cantidad de filtros

Puesto que no existe la manera precisa de conocer los valores, para obtener buenos resultados de clasificación, se realizaron pruebas experimentales, escogiendo los valores de tamaño de filtros, y de capas al azar, los resultados se pueden observar en la **Tabla 3**.

Tabla 3.
Resultados del entrenamiento al modificar la red Alexnet

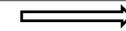
N	Descripción			PR	PE	PEt	TE (min)	TC (ms)	AUC
1	Arquitectura original	48 filtros	Kernel: 11 Stride: 4	0,986	0,064	0,029	244	4,81	0,827
2		96 filtros	Kernel: 11 Stride: 4	0,989	0,06	0,009	225	5,74	0,86
3		192 filtros	Kernel: 11 Stride: 4	0,991	0,053	0,005	260	7,15	0,841
4	1 Convolución 1 ReLU	48 filtros	Kernel: 11 Stride: 4	0,982	0,059	0,034	273	4,92	0,825
5		96 filtros	Kernel: 11 Stride: 4	0,988	0,069	0,03	264	5,77	0,872
6		192 filtros	Kernel: 11 Stride: 4	0,988	0,065	0,03	252	7,41	0,865
7	2 Convolución 2 ReLU	48 filtros	Kernel: 11 Stride: 4	0,983	0,072	0,046	278	4,98	0,836
8		96 filtros	Kernel: 11 Stride: 4	0,984	0,078	0,051	276	6,56	0,842
9		192 filtros	Kernel: 11 Stride: 4	0,986	0,078	0,027	288	8,07	0,872
10	3 Convolución 3 ReLU	48 filtros	Kernel: 11 Stride: 4	0,983	0,071	0,034	312	4,91	0,824
11		96 filtros	Kernel: 11 Stride: 4	0,983	0,083	0,018	324	6,83	0,838
12		192 filtros	Kernel: 11 Stride: 4	0,985	0,074	0,051	300	7,89	0,807
13	4 Convolución 4 ReLU	48 filtros	Kernel: 11 Stride: 4	0,978	0,063	0,029	312	5,78	0,835

CONTINÚA



14		96 filtros	Kernel: 11 Stride: 4	0,987	0,065	0,024	332	7,58	0,841	
15		192 filtros	Kernel: 11 Stride: 4	0,988	0,065	0,032	328	8,58	0,84	
16	1 Convolución 1 ReLU	48 filtros	Kernel: 11 Stride: 4	0,989	0,058	0,023	287	5,46	0,835	
17		96 filtros	Kernel: 11 Stride: 4	0,993	0,05	0,018	272	5,95	0,859	
18		192 filtros	Kernel: 11 Stride: 4	0,992	0,048	0,009	294	7,66	0,837	
19		48 filtros	Kernel: 11 Stride: 4	0,991	0,054	0,017	308	8,18	0,871	
20				Kernel: 5 Stride: 3	0,891	0,057	0,028	292	11,12	0,891
21	2 Convolución 2 ReLU	96 filtros	Kernel: 7 Stride: 4	0,985	0,068	0,078	248	5,62	0,839	
22			Kernel: 11 Stride: 4	0,991	0,053	0,025	280	4,96	0,906	
23			Kernel: 13 Stride: 4	0,993	0,051	0,024	276	3,68	0,776	
24	Disminuir capas	192 filtros	Kernel: 11 Stride: 4	0,988	0,06	0,03	288	6,75	0,878	
25		48 filtros	Kernel: 11 Stride: 4	0,958	0,166	0,267	256	11,51	0,762	
26		3 Convolución 3 ReLU	96 filtros	Kernel: 11 Stride: 4	0,964	0,078	0,032	278	9,46	0,822
27			192 filtros	Kernel: 11 Stride: 4	0,968	0,082	0,028	296	7,39	0,814
28		4 Convolución 4 ReLU	48 filtros	Kernel: 11 Stride: 4	0,963	0,163	0,158	251	3,38	0,802
29	96 filtros		Kernel: 11 Stride: 4	0,971	0,092	0,075	266	5,63	0,825	

CONTINÚA



30	192 filtros	Kernel: 11 Stride: 4	0,974	0,056	0,064	285	7,82	0,818
-----------	-------------	-------------------------	-------	-------	-------	-----	------	-------

PR: Precisión
PE: Pérdida de Evaluación
PEt: Pérdida de Entrenamiento
TE: Tiempo entrenamiento
TC: Tiempo clasificación

4.3 Descripción de arquitectura Fast R-CNN para la clasificación de señales de tránsito

Dado que mejores resultados se obtuvieron al disminuir dos capas de convolución y dos capas ReLU, con un AUC de 0.91 (Ver *Figura 35*), se consideró esta arquitectura para la implementación en este trabajo. En la **Tabla 4**, se presenta la arquitectura para clasificación de señales de tránsito.

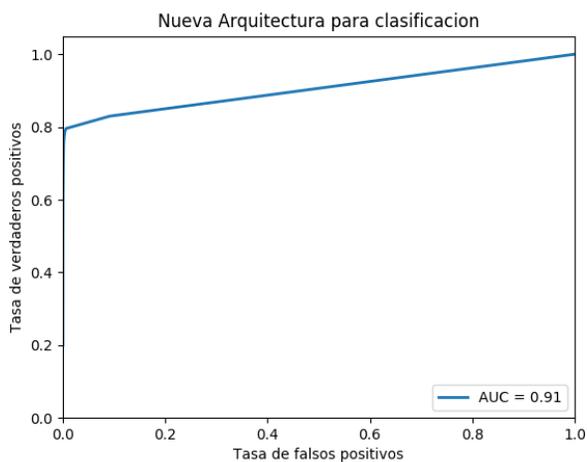


Figura 35. Curva ROC al disminuir 4 capas

Tabla 4.

Arquitectura propuesta para clasificación de señales de tránsito

Nombre	Número de filtros	Tamaño Mapa de caracteres (largo x ancho x canal)	Tamaño del filtro	Paso	Relleno
capa de entrada de imagen		227x227x3			
conv1	96	55x55x96	11x11	4x4	0x0
relu1		55x55x96			
norm1		27x27x96			
pool1	1	27x27x96	3x3	2x2	0x0
conv2	256	27x27x256	5x5	1x1	2x2
relu2		27x27x256			

CONTINÚA ⇨

norm2		13x13x256			
pool2	1	13x13x256	3x3	2x2	0x0
conv3	384	13x13x384	3x3	1x1	1x1
relu3		13x13x384			
Pool3	1	6x6x384	3x3	2x2	0x0
fc6		4096			
relu6		4096			
drop6		4096			
fc7		4096			
relu7		4096			
drop7		4096			
fc8		52			
accuarancy		52			
loss		52			

La arquitectura de la red propuesta en este trabajo para la clasificación de señales de tránsito se muestra en la **Tabla 4**. Esta arquitectura contiene 3 capas convolucionales y 3 capas completamente conectadas (FC), cada capa es seguida de una capa ReLU, (excepto la última capa FC). A continuación de algunas de las capas ReLU hay 3 capas Pooling, culminando la arquitectura con una capa de precisión y una capa Softmax como se puede ver en la Figura 36

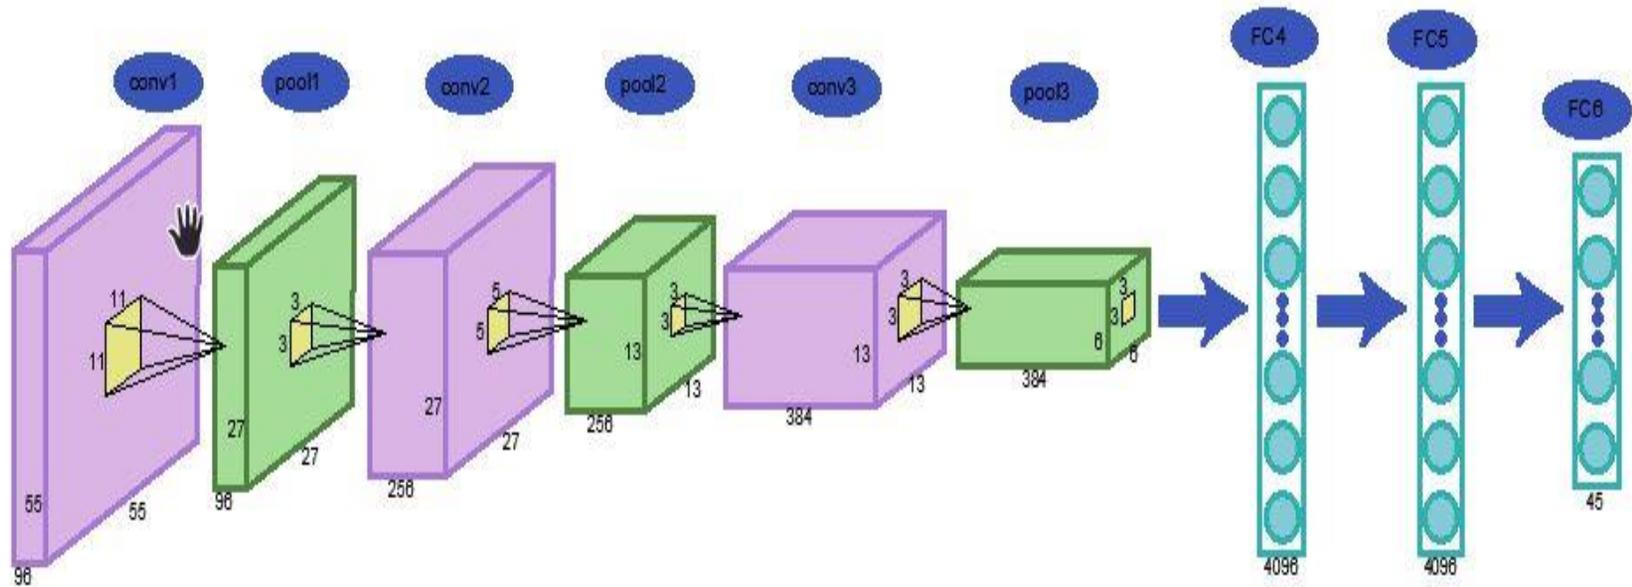


Figura 36. Arquitectura Fast-RCNN propuesta para clasificación señales de tránsito

4.4 Parámetros de entrenamiento de la red

Tabla 5.

Parámetros de entrenamiento de la arquitectura del sistema 1

Parámetro	Valor
Tasa de aprendizaje (base_lr)	0,01
Momentum	0,9
Decaimiento de peso	0,0005
lr_policy	Step
Imágenes por batch	100
gamma	0,1

4.5 Base de datos

La base de datos contiene 48 clases, en 4 ambientes de iluminación (amanecer, día, noche y nublado). En total existen 37500 imágenes, divididas en dos conjuntos: el 75% se utilizó para el entrenamiento, y el 25% para la etapa de pruebas.

CAPÍTULO V

5. PRUEBAS Y RESULTADOS

5.1 Introducción

En el presente capítulo se presenta los resultados obtenidos en las etapas de generación de ROIs y de clasificación, además de los resultados obtenidos en la integración de las etapas previamente mencionadas, logrando de esta manera construir un algoritmo para la detección automática de señales de tránsito preventivas y reglamentarias. La etapa experimental consiste en realizar diferentes pruebas de funcionamiento de desempeño en tiempo real y para días con diferentes condiciones meteorológicas y de iluminación.

5.2 Herramientas utilizadas para la evaluación del detector

El proceso de evaluación se presenta en cuatro partes correspondientes a la evaluación de la etapa de generación de ROIs, de clasificación, la detección y reconocimiento de señales de tránsito (unión de generación de ROIs y clasificación) y finalmente las pruebas de funcionamiento.

5.2.1 Precisión

Siendo:

- TP: Verdaderos positivos
- TN: Verdaderos negativos
- FP: Falsos positivos
- FN: Falsos negativos

La Precisión se calcula como la relación entre TP y FP es decir:

$$\textit{Precisión} = \frac{TP}{TP + FP} \quad (2)$$

5.2.2 Recuperación (Recall)

La recuperación es el porcentaje de señales que recupera el sistema. Es decir:

$$\textit{Recuperación} = \frac{TP}{TP + FN} \quad (3)$$

Y la variación de Recuperación es:

$$\Delta_r(i) = \Delta_r(i) - \Delta_r(i - 1) \quad (4)$$

5.2.3 Curvas ROC (Característica Operativa del Receptor)

Mediante el análisis de curvas ROC (Receiver Operating Characteristics), se evalúa la etapa de generación de ROIs y del clasificador; estas curvas permiten evaluar el rendimiento, presentando en el eje de las abscisas a los falsos positivos y en el eje de las ordenadas los verdaderos positivos; el AUC (Area Under the Curve) de dicha curva representa la probabilidad de un clasificador para clasificar una determinada muestra, generando valores en el rango de 0 a 1; mientras este valor se acerque más a 1 se considera un buen clasificador y para valores menores a 0.5 un mal clasificador (Fawcett, 2004).

5.2.4 Tasa de error versus Falsos Positivos Por Imagen (FPPI)

En la etapa final correspondiente a la detección de señales de tránsito, para el sistema 1 se presenta la curva tasa de error vs FPPI correspondiente a la unión de la etapa de clasificación de píxeles usando color y la etapa de clasificación de señales de tránsito la cual se compara con la curva del sistema 2 correspondiente a la etapa directamente de detección de señales usando una red Fast-RCNN; para ello se comprobará que se hayan detectado y clasificado las señales de tránsito presentes en las imágenes (pruebas realizadas en videos) y cuál es la tasa de FPPI (falsos positivos por imagen) registrada; dicha tasa corresponde a detecciones de señales sobre una región que no contiene una señal de tránsito; la gráfica de tasa de error vs FPPI se usa para evaluar estos casos de falsos positivos y verdaderos negativos, dicha gráfica está basada en el área de superposición entre las regiones que contienen la ubicación real de las señales de tránsito B_{gt} (Bounding Box Ground True) y las regiones detectadas por el algoritmo B_{ts} (Bounding Box traffic signals) (Dollár, Wojek, Schiele, & Perona , 2009) ver (5).

$$a_0 = \frac{\text{area}(B_{ts} \cap B_{gt})}{\text{area}(B_{ROI} \cup B_{gt})} \quad (5)$$

Dónde:

- a_0 : área de superposición
- B_{ts} : regiones detectadas por el algoritmo (Bounding Box Traffic Signals)
- B_{gt} : regiones con la ubicación verdadera de la señal de tránsito (Bounding Box Ground True)

5.2.5 Media de la Precisión Promedio (mAP)

AP es una métrica, que permite determinar la precisión de detectores de objetos. Se obtiene promediando las precisiones máximas a diferentes valores de recuperación.

$$Ap = \sum_{i=1}^N \text{Precisión}(i) * \Delta_r(i) \quad (6)$$

Dónde:

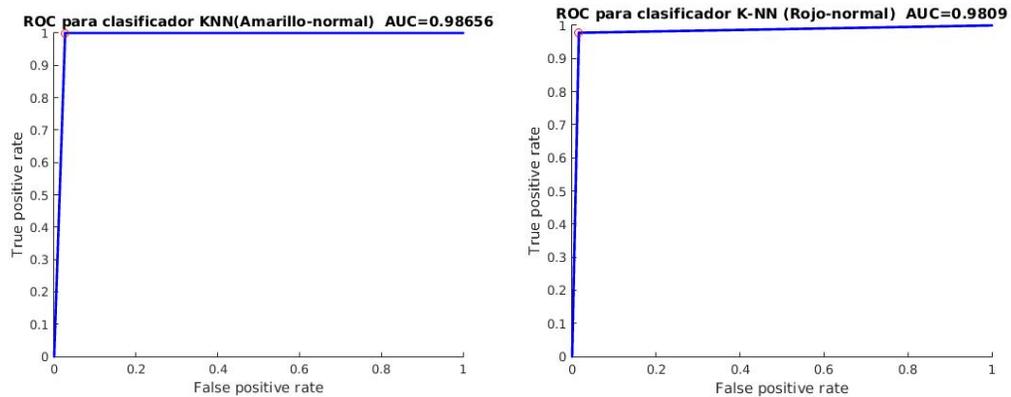
- N: número de imágenes de la colección
- Precisión(i): precisión de los i documentos
- $\Delta_r(i)$: Cambio en la recuperación

El mAP consiste en promediar el valor AP obtenido para cada clase.

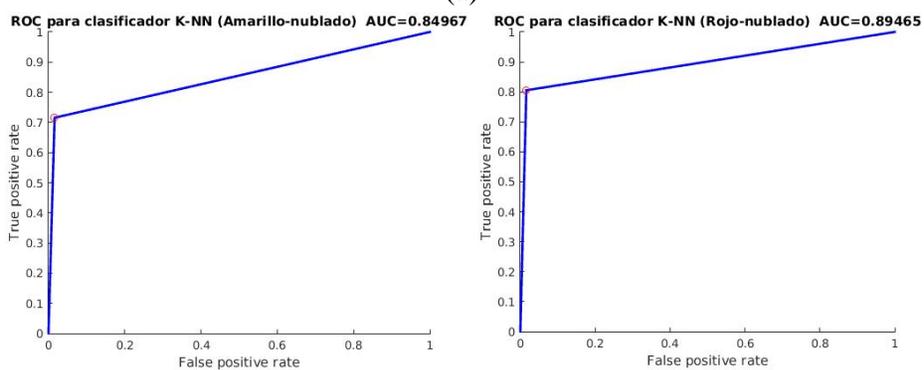
5.3 Evaluación del sistema de detección

5.3.1 Evaluación etapa de clasificación de píxeles usando color

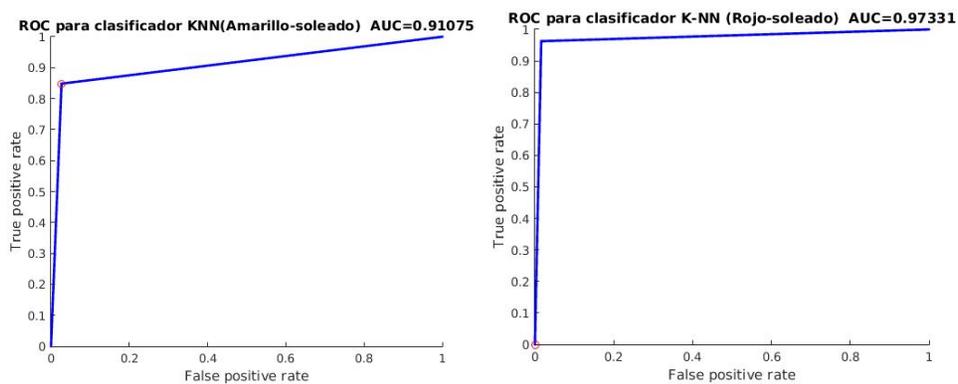
A continuación se presentan las curvas ROC para la clasificación de píxeles usando color correspondientes a las señales de tránsito preventivas (amarillas) y reglamentarias (rojas), para las condiciones de iluminación a) día normal, b) día nublado, c) día soleado, d) representación de las 3 condiciones y e) funcionamiento final; en la Figura 37 usando el clasificador K-NN con k-means, en la Figura 38 usando filtro en el espacio de color HSV, en la Figura 39 la unión entre clasificador K-NN y el filtro en el espacio de color HSV.



(a)



(b)



(c)

CONTINÚA \Rightarrow

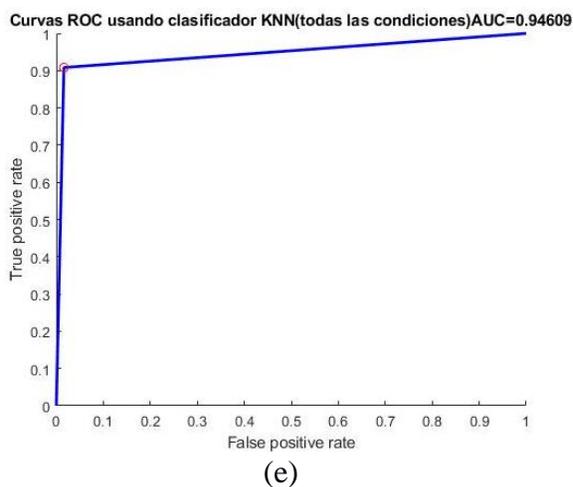
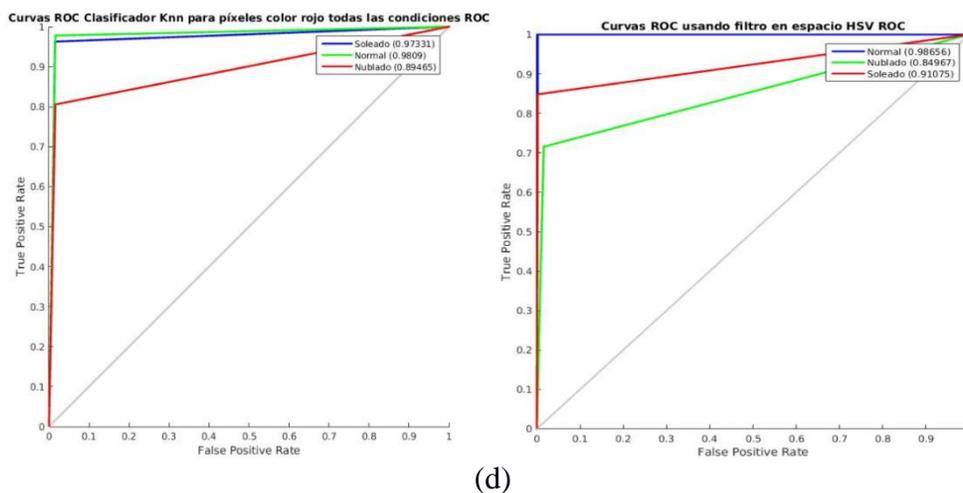
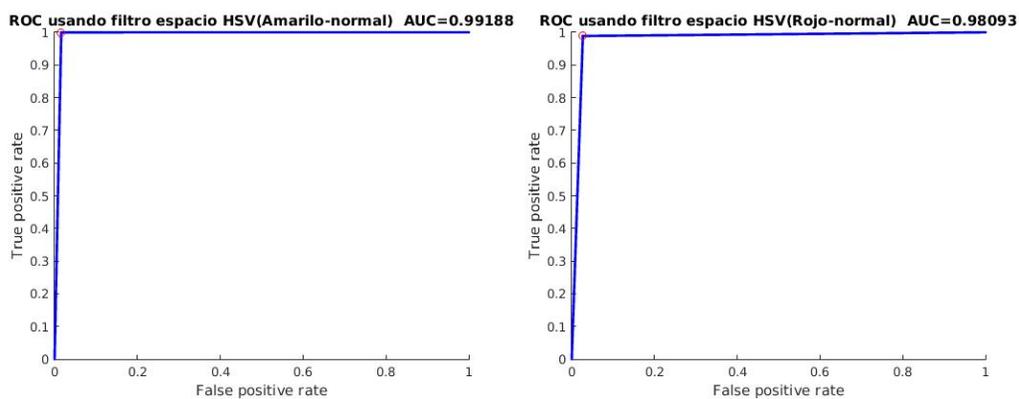
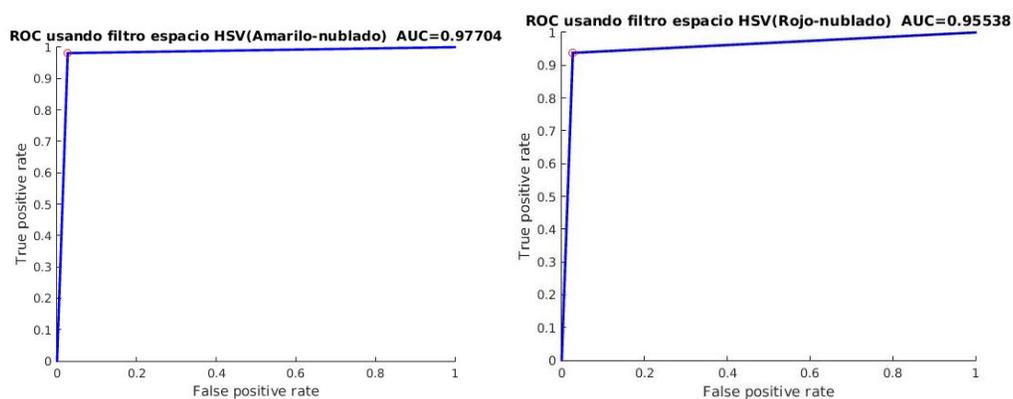


Figura 37. Curvas ROC usando K-NN.

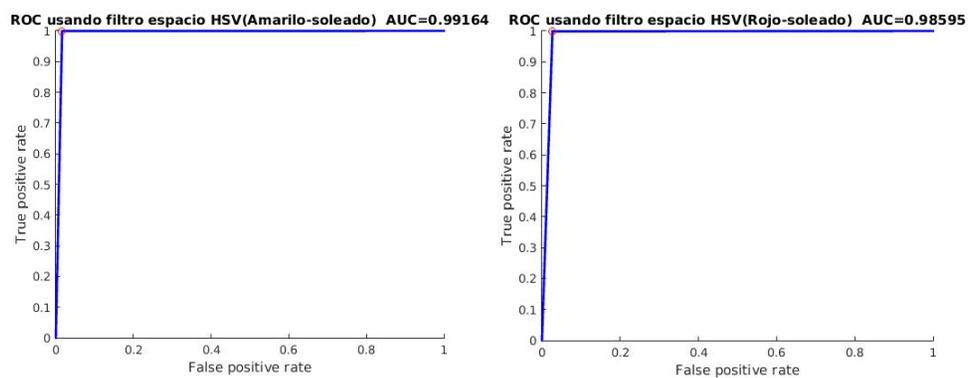
Al comparar los valores AUC de las curvas ROC presentadas en la **Figura 37** se observa que el mejor rendimiento usando el clasificador K-NN se obtiene para las señales preventivas (amarillas) en los días con iluminación normal (Ver **Figura 37_a**) con un AUC de 0.98656 y el rendimiento más bajo se obtiene en las señales reglamentarias (rojas) en días nublados con un AUC de 0.89465 (Ver **Figura 37_b**).



(a)

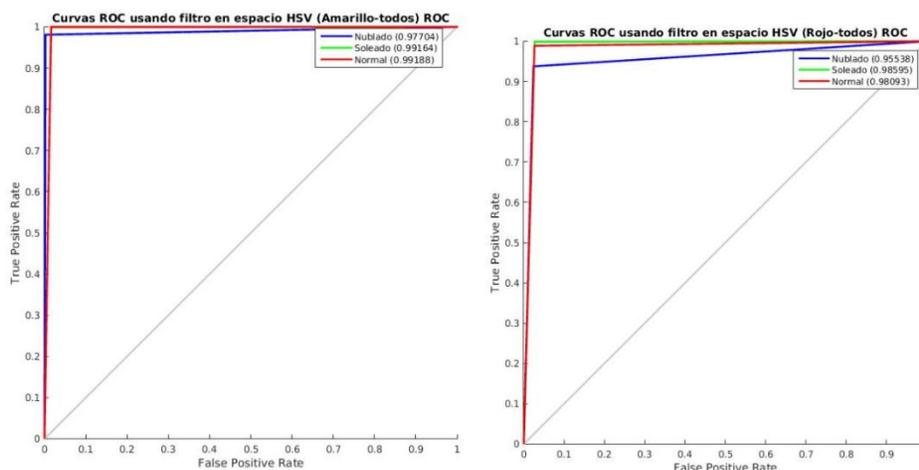


(b)

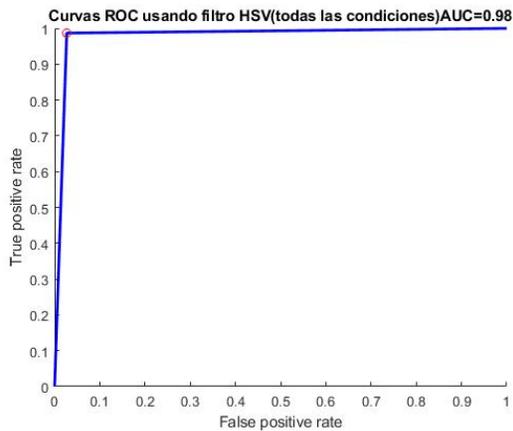


(c)

CONTINÚA \Rightarrow



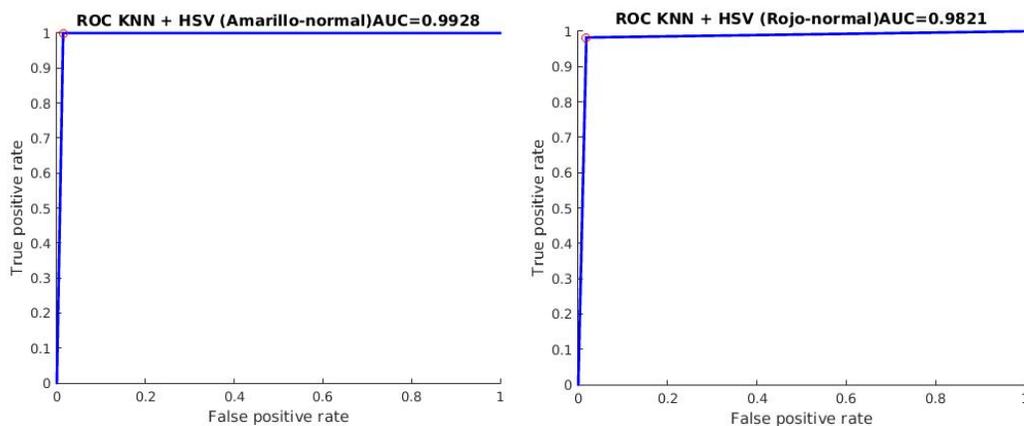
(d)



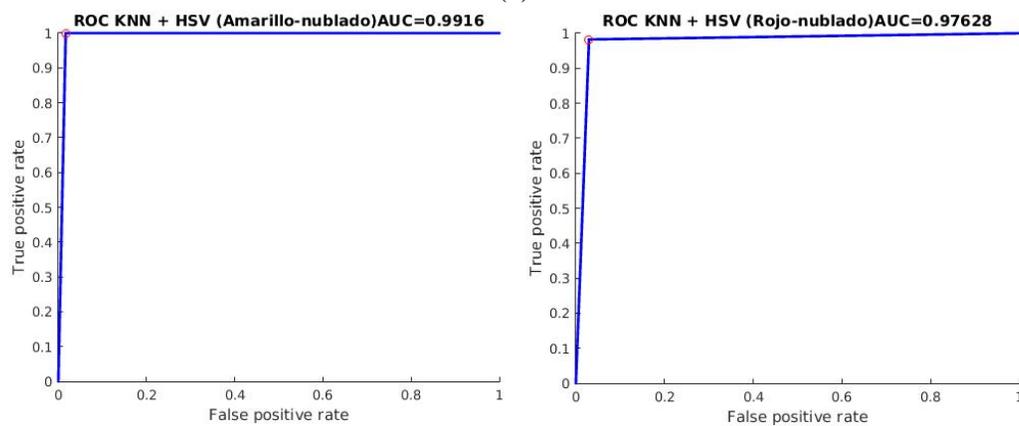
(e)

Figura 38. Curvas ROC usando filtro en espacio de color HSV

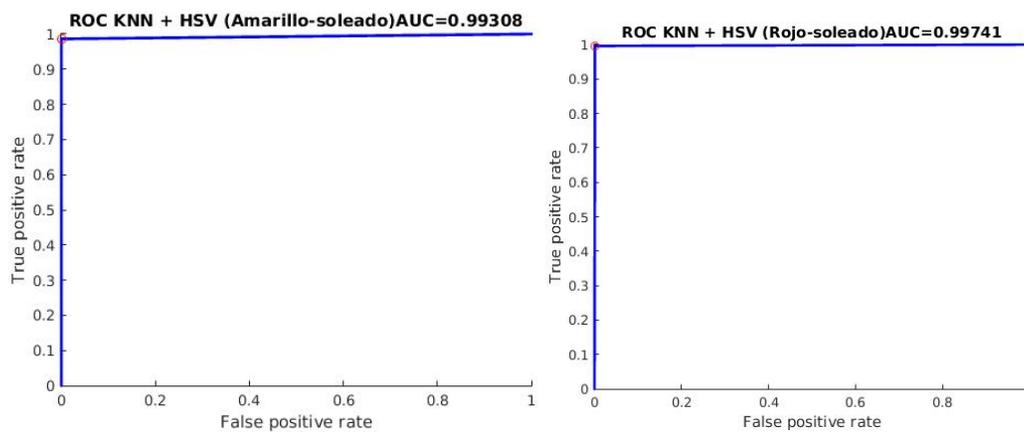
Al comparar los valores AUC de las curvas ROC presentadas en la **Figura 38** se observa que el mejor rendimiento usando filtro en el espacio de color HSV se obtiene para las señales preventivas (amarillas) en los días con iluminación normal (Ver **Figura 38_a**) con un AUC de 0.99188 y el rendimiento más bajo se obtiene en las señales reglamentarias (rojas) en días nublados con un AUC de 0.95538 (Ver **Figura 38_b**).



(a)

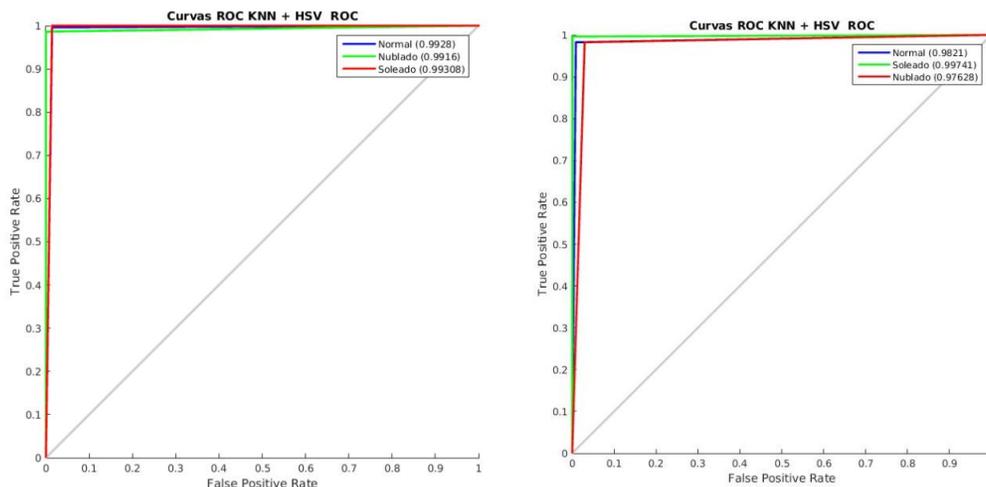


(b)

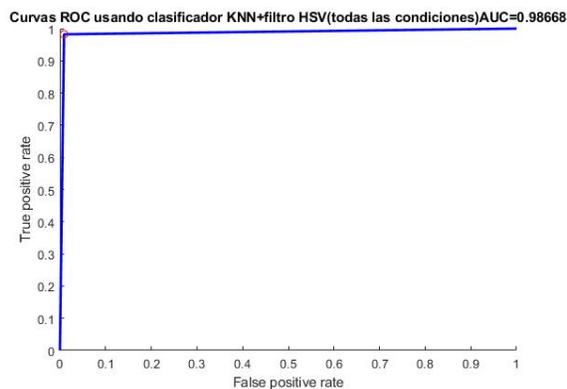


(c)

CONTINÚA \Rightarrow



(d)



(e)

Figura 39. Curvas ROC usando K-NN más filtro en espacio de color HSV.

Al comparar los valores AUC de las curvas ROC presentadas en la **Figura 39** se observa que el mejor rendimiento al unir el clasificador K-NN y el filtro en el espacio de color HSV se obtiene para las señales reglamentarias (rojas) en los días soleados (Ver **Figura 39_c**) con un AUC de 0.99741 y el rendimiento más bajo se obtiene en las señales reglamentarias (rojas) en días nublados con un AUC de 0.97628 (Ver **Figura 39_b**).

5.3.2 Evaluación del método de generación de ROIs

Para comprobar cuantas de las ROIs generadas en la etapa de clasificación usando color contienen en realidad una señal de tránsito se verificó que dicha señal cumpliera con (3) (Kim & Lee, 2013), la condición adicional a (5) indica que para que una ROI sea considerada valida el área de superposición debe superar un umbral establecido en 0.5, siendo descartadas aquellas ROIs por debajo de este umbral.

$$\begin{array}{ll} \text{Si } a_0 > 0.5, & \text{ROI válida} \\ \text{Si } a_0 \leq 0.5, & \text{ROI inválida} \end{array} \quad (7)$$

Dónde:

- a_0 : umbral del área de superposición.

A continuación, en la Figura 40 se observa en (a) la ROI seleccionada manualmente para una señal de tránsito preventiva (color amarillo) y en (b) las ROIs generadas en la etapa de generación de ROIs, concluyendo que para este fotograma se genera una ROI que no es válida.



(a)

CONTINÚA \Rightarrow



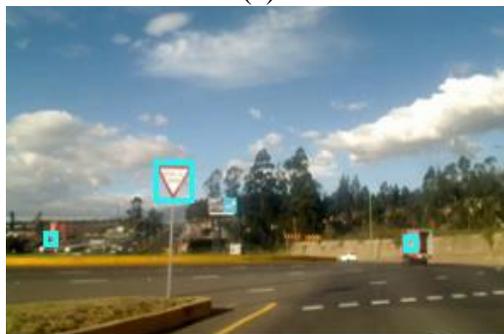
(b)

Figura 40. Comprobación ROIs válidas.

En la **Figura 41** se observa en (a) la ROI seleccionada manualmente de una señal de tránsito reglamentaria (color rojo) y en (b) las ROIs generadas en la etapa de generación de ROIs, concluyendo que para este fotograma se generan 3 ROIs que no son válidas.



(a)



(b)

Figura 41. Comprobación ROIs válidas.



(a)



(b)



(c)

Figura 42. Resultado generación de ROIs.

En la *Figura 42* se observa que para el fotograma analizado se generan 8 ROIs en total (celeste), de las cuales 5 son válidas (rojo).

Para comprobar las ROIs válidas se utiliza la ecuación (5) y la condición (7), para lo cual las ROIs generadas por el algoritmo (*Figura 42* (b) color celeste) y las ROIs seleccionadas de forma manual (*Figura 42* (c) color rojo) deben superar el umbral de 0.5, ver **Tabla 6**.

Tabla 6.
Confirmación de ROIs válidas en un fotograma.

TOTAL					
ROIs	SEÑAL 1	SEÑAL 2	SEÑAL 3	SEÑAL 4	SEÑAL 5
1	0.91	0	0	0	0
2	0	0.89	0	0	0
3	0	0	0.78	0	0
4	0	0	0	0.74	0
5	0	0	0	0	0
6	0	0	0	0	0.88
7	0	0	0	0	0
8	0	0	0	0	0
Núm. ROIs	1	1	1	1	1
ROIs válidas	5				

Para el fotograma analizado se puede concluir que de las 8 ROIs generadas representando un 100%, 5 ROIs son válidas equivalente al 62.5% y 3 ROIs son inválidas equivalentes al 37.5%.

Para poder realizar la comprobación de ROIs se etiquetaron manualmente 3 videos para las condiciones de iluminación en día normal, soleado y nublado de 810, 375 y 759 fotogramas respectivamente; a continuación en la **Tabla 7** se presenta el resumen de las ROIs que fueron aceptadas como válidas es decir aquellas que sobrepasaron el umbral (0.5), para ello se toma en cuenta el número total de fotogramas y el número de señales de tránsito por fotograma, con la finalidad de presentar un promedio para cada video que represente el desempeño de la etapa de generación de ROIs.

Tabla 7.
Evaluación del método de generación de ROIs en videos

VIDEO	Núm. de fotogramas	Total de señales de tránsito (ST)	Promedio de ST por fotograma	Núm. y % de ST detectadas (STD) y ST no detectadas (STND) por video			Prom. y % de ROIs por fotograma	Prom. y % de ROIs con ST por fotograma
				Total Señales de tránsito	STD	STND		
Normal	810	877	1.08	877	872	5	8.13	7.02
				100 %	99.43 %	0.57 %	100 %	86.34 %
Soleado	375	546	1.46	546	540	6	7.04	5.96
				100 %	98.90 %	1.10 %	100 %	84.65 %
Nublado	759	819	1.08	819	809	10	6.42	4.93
				100 %	98.78 %	1.22 %	100 %	76.79 %

Después de analizar y obtener un promedio en porcentajes presentados en la **Tabla 7** se concluye que del 100% de ROIs generadas, el 82.59% de ellas contienen una señal de tránsito y van a la etapa de clasificación.

5.4 Evaluación etapa de clasificación

Además, se realizaron pruebas tanto para señales preventivas como para señales reglamentarias en los diferentes ambientes de iluminación (amanecer, día, noche y nublado), obteniendo un mejor resultado en las señales reglamentarias (b) con una efectividad de 97,5%, respecto a las señales preventivas (a) con una efectividad de 94.8%, como se puede ver en la Figura 43.

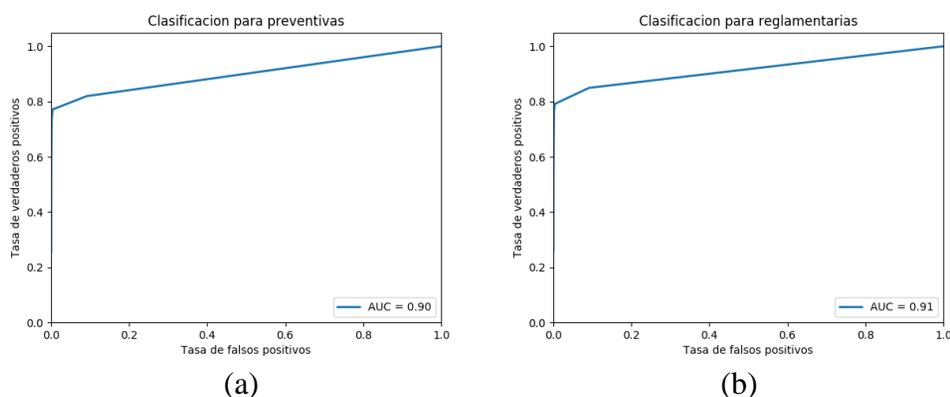


Figura 43. Curva ROC para clasificación.

5.5 Evaluación del detector de señales de tránsito

En esta sección se muestran resultados para dos sistemas diferentes de detección, el Sistema 1 consiste en la unión de la etapa de Generación de ROIs con la etapa de clasificación de señales basada en la arquitectura de propuesta en este trabajo, y el Sistema 2 es la implementación de una red convolución rápida para detección (Matthew D Zeiler, 28 Nov 2013).

En la **Tabla 8** se muestra el valor AP (Average Precision) para cada clase de las señales de tránsito haciendo uso de los dos sistemas. Obteniendo un valor mAP de 75% para el sistema 1 y de 97,6% para el sistema 2.

Tabla 8.
Valores de AP para cada señal

<i>Nombre de la señal</i>	<i>AP Sistema 1</i>	<i>AP sistema 2</i>
Altura limitada 4.20	0,99	0,94
Angostamiento derecho	0,79	0,94
Angostamiento izquierdo	0,14	0,92
Aproximación a ferrocarril	0,39	0,99
Aproximación a redondel	0,88	0,98
Bifurcación a la derecha	0,83	0,89
Calzada resbaladiza	0,72	0,99
Cambio de Trayectoria	0,35	0,92
Cruce a nivel de ferrocarril	0,84	0,97
Cruce de ciclistas	0,91	0,93
Cruce de Ganado	0,81	0,96
Cruce de vías	0,67	0,97
Cruce escolar	0,88	0,94
Cruce peatonal	0,98	0,95
Curva abierta derecha	0,79	0,93
Curva cerrada a la derecha	0,65	0,94
Curva cerrada a la izquierda	0,36	0,95
Curva en U a la derecha	0,83	0,93
Curva se mantiene	0,48	0,98
Curva y contra curva cerradas a la derecha	0,85	0,95
Empalme lateral derecho	0,45	0,95
Incorporación de carril adicional izquierdo	0,89	0,93
Incorporación de tránsito derecho	0,93	0,96
Peligro	0,002	0,96
Pendiente peligrosa	0,66	0,94
Rompe velocidades	0,85	0,96
zona de derrumbe	0,77	0,92
Ceda el paso	0,76	0,95
Límite velocidad 10	0,79	0,98
CONTINÚA 		

Límite velocidad 100	0,92	0,98
Límite velocidad 20	0,92	0,98
Límite velocidad 30	0,87	0,96
Límite velocidad 35	0,80	0,94
Límite velocidad 40	0,90	0,98
Límite velocidad 45	0,86	0,95
Límite velocidad 50	0,92	0,98
Limite velocidad 60	0,85	0,94
Límite velocidad 70	0,95	0,99
Límite velocidad 80	0,77	0,96
Limite velocidad 90	0,90	0,95
No entre	0,84	0,93
No estacionar	0,83	0,97
No girar en U	0,91	0,98
No virar a la izquierda	0,76	0,94
Pare	0,57	0,97
prohibido rebasar	0,72	0,94
Límite velocidad 15	0,84	0,95

En la Figura 44 se muestra el resultado final que tiene una tasa de error de 0.33 en 10^{-1} FPPI para el Sistema 1 (generación de ROIs + clasificación de señales) y de 0.07 en 10^{-1} FPPI para el Sistema 2 ((Matthew D Zeiler, 28 Nov 2013)), para condiciones de iluminación normal, nublado y soleado

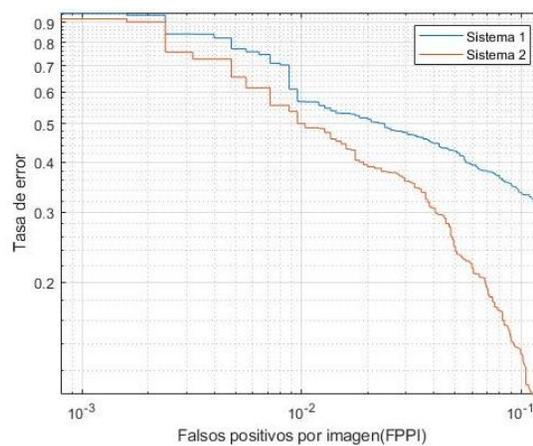


Figura 44. Tasa de error versus FPPI

5.6 Ejemplos de funcionamiento de detección de señales de tránsito

Las pruebas de funcionamiento del sistema de detección y reconocimiento de señales de tránsito se realizaron en las calles de la ciudad de Quito, en diferentes días y horas para poner a prueba la efectividad del sistema en los diferentes ambientes de iluminación, estos resultados se presentan en la *Figura 45*, *Figura 46*, *Figura 47* y *Figura 48*, observando una mejora en el sistema 2 (derecha) con respecto al sistema 1 (izquierda), en el cual se puede observar un mayor número de falsos positivos.



Figura 45. Ejemplos de funcionamiento con iluminación normal

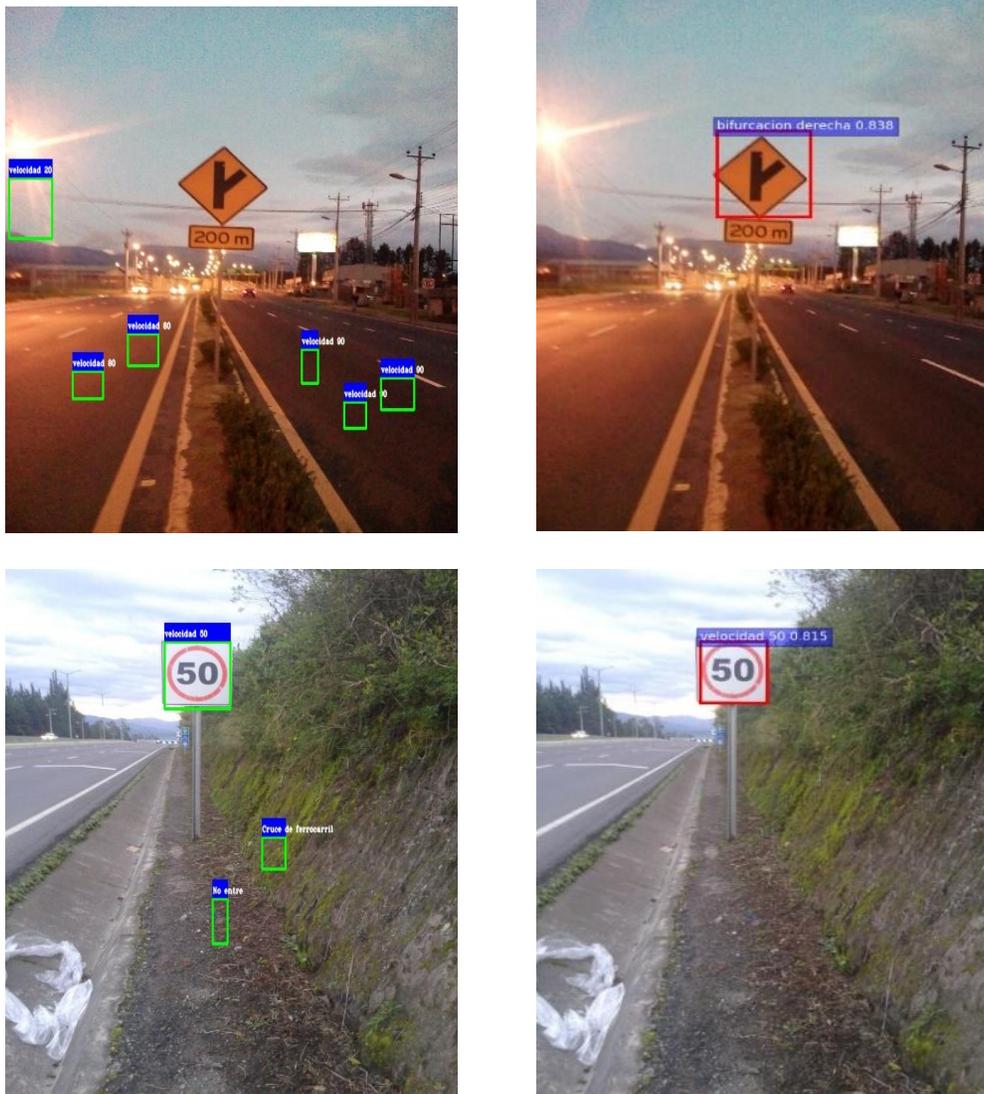


Figura 46. Ejemplos de funcionamiento con iluminación al amanecer

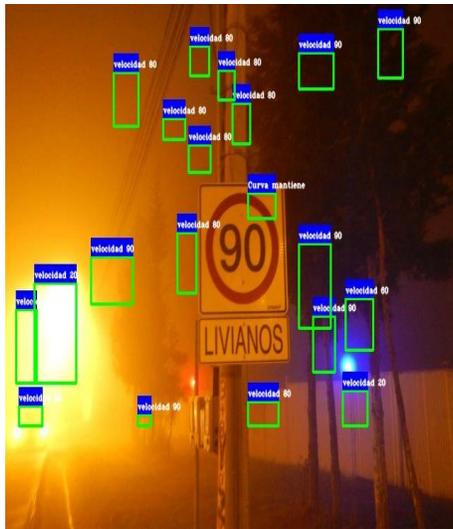


Figura 47. Ejemplos de funcionamiento durante días nublados



Figura 48. Ejemplos de funcionamiento durante la noche

En la **Figura 49**. Se muestra los ejemplos de falsas detecciones en las diferentes condiciones de iluminación utilizando el sistema 1



(a)



(b)



(c)



(d)

Figura 49. Ejemplos de falsas detecciones con el sistema 1.

CAPÍTULO VI

6. CONCLUSIONES Y RECOMENDACIONES

6.1 Conclusiones

En el siguiente trabajo de investigación se presentó un algoritmo para detectar señales de tránsito preventivas y reglamentarias del Ecuador, las principales conclusiones son:

- El algoritmo de clasificación K-NN en comparación con el filtro en el espacio HSV presenta cierta desventaja en base a rendimiento, esto se debe a que K-NN realiza una comparación pixel a pixel ya que se trabaja en el espacio de color RGB normalizado y para este espacio todos sus canales contienen color; la ventaja del filtro es que al usar el espacio HSV este contiene un canal específico para color, por lo que se realizó la implementación del clasificador K-NN con k-means más el filtro mencionado para obtener mejores resultados.
- La construcción de una arquitectura basada en red neuronal convolucional rápida del tipo AlexNet. Al variar los diferentes parámetros, como el tamaño del kernel, el tamaño de los filtros y la cantidad de capas, se determinó que los mejores resultados se obtuvieron al disminuir la cantidad de capas. Llegando a 3 capas convolucionales, 3 pooling y 3 FC para la clasificación de 48 clases. La tasa de clasificación es 0,91.
- El detector obtuvo un mAP de 75%, que es un avance importante en la clasificación al comparar con otros algoritmos presentes en el estado del arte usando técnicas basadas en el color. A la vez es inferior a una detección puramente basada en aprendizaje profundo.

- La tasa de error versus FPPI es de 0.33 en 10^{-1} FPPI para el sistema 1 y 0.07 en 10^{-1} FPPI para el sistema 2.

6.2 Recomendaciones

Para la etapa de generación de ROIs es importante considerar los inconvenientes que se presentan al realizar una segmentación basada en color debido a los diferentes cambios de iluminación presentes en el día, además de factores externos que influyen como las oclusiones, deterioro o pegatinas presentes en las señales de tránsito.

6.3 Trabajos futuros

- Mejorar la base de datos en cantidad, calidad y variabilidad de las imágenes para mejorar la etapa de clasificación, incluyendo imágenes capturadas en la noche, sol extremo, nublado; para así tener un sistema robusto en cualquier ambiente de iluminación diurno como nocturno.

7. BIBLIOGRAFÍA

- (s.f.).
- Agencia Nacional de Tránsito. (2008-2016). *Agencia Nacional de Tránsito*. Obtenido de <http://www.ant.gob.ec/>
- Agencia Nacional de Tránsito. (2014-2016). *Agencia Nacional de Tránsito*. Obtenido de <http://www.ant.gob.ec/>
- Agencia Nacional de Tránsito. (2016). *Agencia Nacional de Tránsito*. Obtenido de <http://www.ant.gob.ec/>
- Agencia Nacional de Tránsito. (2016). *ANT*. Obtenido de <http://www.ant.gob.ec/index.php/transito-2/nacional>
- Aguilar Carrera, G. (2005). *Procesamiento digital de imágenes utilizando filtros morfológicos*.
- Alex Krizhevsky, I. S. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *NIPS'12 Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1*, 1097-1105.
- Anuario de transporte. (2016). *INEC-Anuario de transporte 2016*. Obtenido de http://www.ecuadorencifras.gob.ec/documentos/web-inec/Estadisticas_Economicas/Estadistica%20de%20Transporte/2016/2016_AnuarioTransportes_%20Principales%20Resultados.pdf
- Aoyagi, Y., & Asakura, T. (2006). A study on traffic sign recognition in scene image using genetic algorithms and neural networks. *IEEE Industrial Electronics, Control, and Instrumentation*.
- Arriagada García, C., & Aracena Pizarro, D. (2007). Detection and Recognition of traffic signals using Matching of Chamfer. *Ingeniare. Revista chilena de ingeniería*.
- Arriagada Rodríguez, M. (2015). *Comparación de métricas de distancia en el algoritmo K-Vecinos más cercanos para el problema de Reconocimiento Automático de Dígitos Manuscritos*.
- Barnes, N., & Zelinsky, A. (2008). Real timespeed sign detection using the radial symmetry detector. *IEEE Trans. Intell Transp.*
- Barreno, L., & Flores-Calero, M. (2017). *Sistema Automático de detección de peatones en la noche usando información visual en el infrarrojo lejano basado en Redes Neuronales Convolucionales*. Quito.
- Belaroussi, R., Foucher , P., Tarel J, Soheilian, B., Charbonnier , P., & Paparoditis , N. (2010). Road Sign Detection in Images: A Case Study. *IEEE Xplore*.
- Bengio, Y. (2009). Learning Deep Architectures for AI. *Foundations and Trends in Machine Learning*.
- Berzal, F. (s.f.). *Computing Reviews-Clustering basado en particiones*. Obtenido de <http://elvex.ugr.es/idbis/dm/slides/41%20Clustering%20-%20Partitional.pdf>
- BOSCH. (2013). *Night Vision Plus*. Obtenido de http://www.xn--boschtecnologadelautomvilroclp.es/es/es/driving_comfort_8/driving_comfort_systems_for_passenger_cars_9/driv er_assistance_systems_34/driver_assistance_systems_5.html#
- Brkic, K. (s.f.). An overview of traffic sign detection methods.
- Broggi, A. C. (2007). Real time road signs recognition. In Proceedings of the IEEE Intelligent Vehicles. *IEEE*, 981–986.
- Calvo, D. (s.f.). *Diego Calvo*. Obtenido de Diego Calvo: <http://www.diegocalvo.es/red-neuronal-convolucional-cnn/>

- Calvo, J. C. (2013). *Control de un Robot Mediante Técnicas de Visión*. Barcelona.
- Carbajo Benito, Á. (2015). *Desarrollo de una aplicación Android para la detección de señales de tráfico*. Madrid.
- Castellano, J. M. (2010). *Detección Automática de Señales de Tráfico*.
- Christian Szegedy, . W. (2015). Going Deeper with Convolutions. *IEEE Explore*.
- Ciresan D., M. U. (2012). Multi-column deep neural network for traffic sign classification.
- Conlago Guatemal, C. R., & Yunda Sangoluisa, J. A. (2016). *Sistema Automático de detección y reconocimiento de señales de tránsito en intersecciones viales para aplicaciones en vehículos inteligentes*. Quito.
- Convolutional Neural Networks for Visual Recognition*. (s.f.). Obtenido de <http://cs231n.github.io/convolutional-networks/>
- Cost, S., & Salzberg, S. (1993). A Weighted Nearest Neighbor Algorithm for Learning with Symbolic Features. *Machine Learning*, 57-58. Obtenido de <http://www.sc.edu/es/ccwbayes/docencia/mmcc/docs/t9knn.pdf>
- Cristián Arriagada García, D. A.-P. (2007). *Detección y reconocimiento de señales de tránsito utilizando Matching de Chamfer*.
- Cruzado Hernando , D. (2015). *Detección y reconocimiento de señales de tráfico*. Madrid.
- Damavandi, Y. B., & Mohammadi, K. (2004). Speed limit traffic sign detection and recognition . *IEEE Conference on Cybernetics and Intelligent Systems*.
- Dan Cireşan, U. M. (2012). Multi-Column Deep Neural Network for Traffic Sign Classification.
- De La Cruz , J. (2017). *Implementación de un software para la detección y reconocimiento de señales de tráfico en tiempo real a partir de un vídeo capturado en un vehículo en circulación*. Valencia.
- de la Escalera, A., Armingol, J., & Mata, M. (2003). Traffic sign recognition and analysis for intelligent vehicles. *Image and Vision Computing*.
- Deshpande, A. (s.f.). *Adit Deshpande*. Obtenido de <https://adeshpande3.github.io/adeshpande3.github.io/A-Beginner's-Guide-To-Understanding-Convolutional-Neural-Networks/>
- Dollár, P., Wojek, C., Schiele, B., & Perona , P. (2009). Pedestrian Detection: A Benchmark. *IEEE*, 304-311.
- Duda, R., Hart , P., & Stork, D. (2001). *Pattern Classification*.
- Fawcett, T. (2004). *ROC graphs: Notes and practical considerations for researchers Machine learning*.
- FITSA. (2012). *Descripción del sistema de alerta de cambio involuntario de carril y evidencias científicas de su eficacia*. Obtenido de https://espacioseguro.com/fundacionfitsa0/admin/_fitsa/archivos/publicaciones/0000027/03-Cambio_carril.pdf
- Ford. (2017). *Sistema de estacionamiento asistido "manos libres"*. Obtenido de <https://www.ford.pe/tecnologia/sistema-de-estacionamiento-asistido/>
- Franke, U., Gavrilá , D., G`orzig, S., Lindner, F., Paetzold, F., & W`ohler, C. (1999). Autonomous driving approaches downtown. *IEEE Intell.Syst*.
- František Duchon. (2012). Intelligent vehicels as the robotic applications. *Procedia Engineering* 48, 105-114.
- Gao, X. W. (2006). Recognition of traffic signs based on their colour and shape features extracted using human vision models. *Journal of Visual Communication and Image Representation*,

- 17(4):675–685.
- Girshick, R. (2015). Fast R-CNN. *Computer Vision Foundation*.
- Gómez Moreno, H., Maldonado Bascón, S., Gil Jiménez, P., & Lafuente Arroyo, S. (2010). Goal Evaluation of Segmentation Algorithms. *IEEE Transactions on Intelligent Transportation Systems*.
- González, R., & Woods, R. (2008). *Digital Image Processing*.
- Haloi, M. (2015). A novel pLSA based Traffic Signs Classification System.
- Hatzidimos. (2004). Automatic Traffic Sign Recognition in Digital Images.
- INEC. (s.f.). *Anuario de Transportes 2008-2015*. Obtenido de <http://www.ecuadorencifras.gob.ec/anuarios-de-transporte-2/>
- INEN. (2011). *Señalización vial. Parte 1: Señalización vertical*. Obtenido de http://www.normalizacion.gob.ec/wp-content/uploads/downloads/2013/11/prte_004_1_1r.pdf
- Instituto Nacional de Estadística y Censos. (2016). *INEC*. Obtenido de <http://www.ecuadorencifras.gob.ec/transporte/>
- Jiménez F, Gómez Ó, Naranjo J, Serradilla F, López J, Martín A. (s.f.). *Sistemas Avanzados de Asistencia al Conductor*. Obtenido de http://oa.upm.es/11234/1/INVE_MEM_2011_102721.pdf
- Khan, J. F., Bhuiyan, S. M., & Adhami, R. R. (2011). Image segmentation and shape analysis for road-sign detection. *IEEE Trans. Intell, Transp. Syst.*
- Khan, J., Adhami, R., & Bhuiyan, S. (2009). Image segmentation based road sign detection. *IEEE Southeastcon*, 24-29.
- Kim, D. S., & Lee, K. H. (2013). Segment-based region of interest generation for pedestrian detection in far-infrared images. *Infrared Physics & Technology*.
- Le, T., Tran, S., Mita, S., & Nguyen, T. (2010). Real Time Traffic Sign Detection Using Color and Shape-Based Features. *Lecture Notes in Computer Science*.
- Li, H., Sun, F., Liu, L., & Wang, L. (2015). A novel traffic sign detection method via color segmentation and robust shape matching.
- Lillo Castellano, J. M. (2010). *Detección Automática de Señales de Tráfico Mediante Procesamiento Digital de Imagen*. Madrid.
- Lopez, L. D., & Fuentes, O. (2007). Color-Based road Sign Detection and Tracking.
- Maldonado Bascon, S. A. (2010). An optimization on pictogram identification for the road-sign recognition task using SVMs. *Computer Vision and Image Understanding*, 114(3):373–383.
- Maldonado, B. S. (2007). Road-sign detection and recognition based on support vector machines. *IEEE Trans. Intell, Transp. Syst.*
- Mariella Berger, A. F. (2013). Traffic Sign Recognition with WiSARD and VG-RAM Weightless Neural Networks. *Journal of Network and Innovative Computing*, 87-98.
- Mateo, J. E. (2017). *Implementación de un software para la detección y reconocimiento de señales de tráfico en tiempo real a partir de un video capturado en un vehículo en circulación*.
- Matthew D Zeiler, R. F. (28 Nov 2013). Visualizing and Understanding Convolutional Networks .
- Mecánica, A. a. (2014). *Sistema de Aparcamiento asistido*. Obtenido de <http://www.aficionadosalamecanica.com/sistema-aparcamiento-asistido.htm>

- Microsoft, R. G. (s.f.). Fast R-CNN. *IEEE*, 1440-1457.
- Moutarde, F. B. (2007). Robust on-vehicle real-time visual detection of american and european speed limit signs with a modular traffic signs recognition system. In Proceedings of the IEEE Intelligent Vehicles Symposium. *IEEE Press.*, 1122–1126.
- Organización Mundial de la Salud. (2015). *Informe sobre la situación mundial de la seguridad vial 2015*. Obtenido de http://www.who.int/entity/violence_injury_prevention/road_safety_status/2015/Summary_GSRRS2015_SPA.pdf?ua=1
- Organización Panamericana de la Salud. (2016). *La seguridad vial en la región de las Américas*. Washington, D.C.
- Organización Panamericana de la Salud. (2017). *Grupo de colaboración de las Naciones Unidas para la seguridad vial*. Obtenido de http://www.paho.org/hq/index.php?option=com_content&view=article&id=13210%3Asemana-de-seguridad-vial-2017&catid=5230%3Aroad-safety&Itemid=39873&lang=es
- Pankaj, T., & Patil, M. (2013). Recognition of Traffic Symbols Using K-Means and Shape Analysis.
- RACC. (2011). *Sistemas de reconocimiento de señales de tráfico en turismos*. Obtenido de http://imagenes.w3.racc.es/uploads/file/22207_Sistema_Reconocimiento_Seniales.pdf
- Real Academia Española. (s.f.). *Diccionario de la lengua española*. Obtenido de www.rae.es
- Ren, S., He, K., Girshick, R., & Sun, J. (s.f.). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks.
- Reza Azad, B. A. (Enero 2014). Optimized Method for Iranian Road Signs Detection and Recognition System. *International Journal of Research in Computer Science*, 19-26.
- Rocha, C. A., & Escorcía, J. R. (2010). Sistema de Visión Artificial para la Detección y el Reconocimiento de Señales de Tráfico basado en Redes Neuronales. *Eighth LACCEI Latin American and Caribbean Conference for Engineering and Technology*.
- Rocha, C. A., & Gutierrez, J. R. (2010). *Sistema de visión artificial para la detección y el reconocimiento de señales de tránsito basado en Redes Neuronales*.
- Rojas Henríquez, J., & Aracena Pizarro, D. (2013). Segmentación de patentes vehiculares mediante técnicas de agrupamiento en ambientes externos. *Revista Chilena de Ingeniería*.
- Salazar Zapata, L., Patiño, D., & Willian Branch, J. (2011). Clasificación automática de imágenes de cinco tipos de setas usando las metodologías: Bag of Words y Saliency maps. *Symposium on image, Signal processing and Artificial Vision*.
- Stallkamp J., S. M. (2012). Man vs. computer: Benchmarking machine learning algorithms for traffic sign recognition Neural Networks.
- Stancilescu, F. (2012). Real Time Traffic Sign detection using tree classifiers. *IEEE transactions*, 13.
- Standford. (s.f.). *CS231n Convolutional Neural Networks for Visual Recognition*. Obtenido de <http://cs231n.github.io>
- Valeo, M. (2015). *Sistema de detección facial en tiempo real con sistema pan tilt en movimiento continuo*. Sevilla.
- Valero, J. (6 de abril de 2016). *hipertextual*. Obtenido de <https://hipertextual.com/2016/04/control-de-velocidad-adaptativo-traffic>
- Vásquez, B. R. (2012). *Sistema de reconocimiento de señales de tráfico basado en modelos ocultos de Markov*.

- Villalón, G., Torres, M., & Flores-Calero, M. (2017). Sistema de detección de señales de tráfico para la localización de intersecciones viales y frenado anticipado. *Iberoamericana de Automática e Informática Industrial RIAI*, 152-162.
- Villalón, G., Torres, M., & Flores-Calero, M. (2017). Sistema de detección de señales de tráfico para la localización de intersecciones viales y frenado anticipado. *Revista Iberoamericana de Automática e Informática Industrial*, 152–162.
- Vliet, L., & Young, I. (2009). *A nonlinear Laplace operator as edge detector in noisy images*.
- Y. LeCun, L. B. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*.
- Yang, H. M., Liu, C. L., & Huang, S. M. (2013). Traffic Sign Recognition in Disturbing Environments .
- Yang, H., Liu, C., & Huang, S. (2003). Traffic Sign Recognition in Disturbing Environments.
- Yok-Yen Nguwi, T.-T. T.-Y. (s.f.). Real Time Road Sign Recognition.
- Yujun Zeng, X. X. (s.f.). Traffic Sign Recognition Using Extreme Learning Classifier with Deep Convolutional Features.
- Zaklouta, F., & Stanciulescu, B. (2014). Real-time traffic sign recognition in three stages. *Robotics and Autonomous Systems*.
- Zeng, Y., Xu, X., Fang, Y., & Zhao, K. (2015). Traffic Sign Recognition Using Extreme Learning. 1-3.
- Zhe Zhu, D. L. (s.f.). Traffic-Sign Detection and Classification in the Wild. *IEEE*, 2110-2118.