



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: RECONOCIMIENTO DE SEÑALES DE TRÁNSITO DE
VELOCIDAD EN CONDICIONES EXTREMAS DE
ILUMINACIÓN EN EL ESPECTRO VISIBLE**

AUTOR: VARGAS FLORES, JONATHAN RENATO

DIRECTOR: Dr. FLORES CALERO, MARCO JAVIER

SANGOLQUÍ

2018

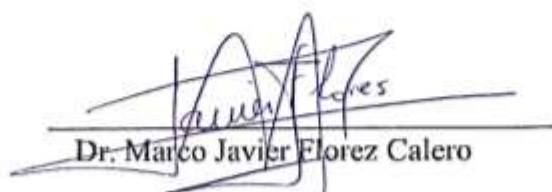


DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA
CARRERA DE INGENIERÍA EN ELECTRÓNICA, AUTOMATIZACIÓN Y
CONTROL

CERTIFICACIÓN

Certifico que el trabajo de titulación, **“RECONOCIMIENTO DE SEÑALES DE TRÁNSITO DE VELOCIDAD EN CONDICIONES EXTREMAS DE ILUMINACIÓN EN EL ESPECTRO VISIBLE”** realizado por el señor **JONATHAN RENATO VARGAS FLORES**, ha sido revisado en su totalidad y analizado por el software anti-plagio, el mismo cumple con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Universidad de Fuerzas Armadas ESPE, por lo tanto me permito acreditarlo y autorizar al señor **JONATHAN RENATO VARGAS FLORES** para que lo sustenten públicamente.

Sangolquí, 19 de febrero del 2018



Dr. Marco Javier Florez Calero



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

AUTORÍA DE RESPONSABILIDAD

Yo, **JONATHAN RENATO VARGAS FLORES**, con cédula de identidad N° 1722160353, declaro que este trabajo de titulación **“RECONOCIMIENTO DE SEÑALES DE TRÁNSITO DE VELOCIDAD EN CONDICIONES EXTREMAS DE ILUMINACIÓN EN EL ESPECTRO VISIBLE”** ha sido desarrollado considerando los métodos de investigación existentes, así como también se ha respetado los derechos intelectuales de terceros considerándose en las citas bibliográficas.

Consecuentemente declaro que este trabajo es de mi autoría, en virtud de ello me declaro responsable del contenido, veracidad y alcance de la investigación mencionada.

Sangolquí, 19 de febrero del 2018

Jonathan Renato Vargas Flores
CC: 1722160353



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

AUTORIZACIÓN

Yo, **JONATHAN RENATO VARGAS FLORES**, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar en la biblioteca Virtual de la institución el presente trabajo de titulación **“RECONOCIMIENTO DE SEÑALES DE TRÁNSITO DE VELOCIDAD EN CONDICIONES EXTREMAS DE ILUMINACIÓN EN EL ESPECTRO VISIBLE”** cuyo contenido, ideas y criterios son de mi autoría y responsabilidad.

Sangolquí, 19 de febrero del 2018



Jonathan Renato Vargas Flores
CC: 1722160353

DEDICATORIAS

A mis padres, Juan y Elena por su ayuda y amor infinito que me han entregado en todo momento de mi vida, han sido la base de todos mis logros y mi ejemplo a seguir, mostrándome que con esfuerzo, trabajo y amor se puede alcanzar cualquier meta.

A cada una de las personas que conforman mi maravillosa familia, por haberme brindado siempre su apoyo en todas las etapas de mi formación personal y profesional, gracias a su apoyo pude conseguir este logro.

A mi novia, Lisseth Fierro, por comprenderme y apoyarme incondicionalmente, porque en los momentos más difíciles siempre estuviste dándome ánimos y fuerzas para seguir, eres mi inspiración y motivación.

Jonathan Renato Vargas Flores

AGRADECIMIENTOS

Agradezco a Dios, por permitirme compartir este logro con mi familia y amigos, por darme la fuerza y sabiduría para conseguir una meta más en mi formación profesional.

A mis padres, por haberme apoyado y motivado en mi formación académica, por estar presentes en todo momento y por todos los sacrificios que han hecho por mi hermano y por mí.

A todos los que forman parte de mi familia, por ayudarme en todo momento y siempre entregarme sus mejores deseos.

A todos los amigos que fueron parte de mi vida, por compartir alegrías, tristezas y su conocimiento, gracias por compartir tantos lindos momentos.

De manera especial al Doctor Marco Flores por ser una guía fundamental en el desarrollo de este proyecto, por compartir sus conocimientos, su esfuerzo y dedicación para concluir con éxito mi carrera.

Jonathan Renato Vargas Flores

ÍNDICE DE CONTENIDOS

CERTIFICACIÓN	ii
AUTORÍA DE RESPONSABILIDAD	iii
AUTORIZACIÓN	iv
DEDICATORIAS	v
AGRADECIMIENTOS	vi
ÍNDICE DE CONTENIDOS	vii
ÍNDICE DE TABLAS	x
ÍNDICE DE FIGURAS	xi
RESUMEN	xiii
ABSTRACT	xiv
CAPÍTULO I	1
1. INTRODUCCIÓN	1
1.1 Antecedentes.....	1
1.2 Accidentes de tránsito en el Mundo y en el Ecuador.....	2
1.2.1 Accidentes de tránsito en el Mundo.....	2
1.2.1.1 Factores de riesgo en accidentes de tránsito.....	5
1.2.1.2 Accidentes de Tránsito debido al exceso de velocidad.....	7
1.2.2 Accidentes de tránsito en el Ecuador.....	8
1.2.2.1 Accidentes de tránsito en los últimos años.....	9
1.3 Tipos de señales de tránsito en el Ecuador.....	15
1.3.1 Señales regulatorias de prioridad de paso.....	17
1.3.2 Serie de límites máximos.....	18
1.4 Sistemas inteligentes de transporte.....	19
1.4.1 Sistemas avanzados de asistencia a la conducción.....	20
1.4.1.1 Sistemas de reconocimiento de señales de tránsito.....	21
1.5 Justificación e importancia.....	22
1.6 Alcance del proyecto.....	23
1.7 Objetivos.....	25
1.7.1 Objetivo general.....	25
1.7.2 Objetivo específicos.....	25
1.8 Estructura del documento.....	26

CAPÍTULO II	27
2. ESTADO DEL ARTE.....	27
2.1 Introducción.....	27
2.2 Reconocimiento de señales de tránsito.....	30
2.2.1 Método de intensidades de los pixeles de la imagen.....	31
2.2.2 Métodos de extracción de características.....	32
2.2.3 Algoritmos de clasificación	33
2.3 Análisis de las técnicas utilizadas.....	34
CAPÍTULO III.....	39
3. RECONOCIMIENTO DE SEÑALES DE TRÁNSITO REGULATORIAS DEL ECUADOR.....	39
3.1 Introducción.....	39
3.2 Pre-Procesamiento de las imágenes.....	40
3.2.1 Escala de grises de la imagen.....	41
3.2.2 Redimensionamiento de la imagen 32x32 pixeles.....	42
3.2.3 Ecuador aplicado a la imagen.....	42
3.3 Extracción de características usando HOG	43
3.3.1 Cálculo del gradiente.....	44
3.3.2 Cálculo de los histogramas de orientación.....	45
3.3.3 Cálculo del descriptor	47
3.4 Multclasificación de señales de tránsito.....	49
3.4.1 ELM	49
3.4.2 Kd-tree	51
3.4.3 SVM.....	53
3.4.4 Multclasificación de señales regulatorias	54
3.4.5 Multclasificación de señales de límite de velocidad.....	54
CAPÍTULO IV	57
4. PRUEBAS Y RESULTADOS.....	57
4.1 Introducción.....	57
4.2 Tecnología utilizada para la implementación del algoritmo	57
4.3 Base de datos de entrenamiento y validación.....	57
4.4 Entrenamiento del algoritmo	58
4.5 Pruebas de funcionamiento.....	60
4.6 Tiempo de cómputo.....	62

4.7	Conclusiones del capítulo.....	63
CAPÍTULO V.....		64
5.	CONCLUSIONES Y TRABAJOS FUTUROS	64
5.1	Conclusiones.....	64
5.2	Trabajos futuros.....	65
REFERENCIAS BIBLIOGRÁFICAS.....		66

ÍNDICE DE TABLAS

Tabla 1. <i>Las 20 causas principales de muerte a nivel mundial 2015.</i>	3
Tabla 2. <i>Causas probables de accidentes de tránsito a nivel nacional de enero hasta octubre 2017.</i>	14
Tabla 3. <i>Siniestros según día y hora de ocurrencia a nivel nacional - octubre 2017.</i>	15
Tabla 4. <i>Notaciones utilizadas en reconocimiento de señales de tránsito.</i>	30
Tabla 5. <i>Técnicas más relevantes utilizadas para el reconocimiento de señales de tránsito.</i>	34
Tabla 6. <i>Base de datos de entrenamiento señales regulatorias.</i>	58
Tabla 7. <i>Base de datos de pruebas señales regulatorias.</i>	58
Tabla 8. <i>AUC según el número de neuronas en la capa oculta ELM.</i>	59
Tabla 9. <i>AUC de la clasificación para señales regulatorias y de límite de velocidad con Kd-tree, SVM y ELM.</i>	60
Tabla 10. <i>Resultados del algoritmo de reconocimiento de señales regulatorias.</i>	62
Tabla 11. <i>Resultados del algoritmo de reconocimiento de señales de límite de velocidad.</i>	62

ÍNDICE DE FIGURAS

Figura 1. Número de muertes por accidentes de tránsito en el mundo, 2013.	4
Figura 2. Límites de velocidad en carreteras urbanas en el mundo.	7
Figura 3. Tasa de muertes por accidentes de tránsito en la Región Andina 2013.	8
Figura 4. Número de accidentes de tránsito en el país. Período: 2008-2016.	9
Figura 5. Número de accidentes de tránsito en el país Año 2016.	10
Figura 6. Distribución de accidentes de tránsito, según clase Año 2016.	10
Figura 7. Distribución de accidentes de tránsito, según causa Año 2016.	11
Figura 8. Número de heridos en accidentes de tránsito, según causa Año 2016. ...	12
Figura 9. Número de muertos en accidentes de tránsito, según causa.	12
Figura 10. Serie cronológica siniestros de tránsito enero 2016 a octubre 2017.	13
Figura 11. Clasificación de señales de tránsito del Ecuador.	16
Figura 12. Principales señales de tránsito: a) señales regulatorias, b) señales de prevención, c) señales de información.	17
Figura 13. Serie de prioridad de paso: a) señal pare, b) ceda el paso.	18
Figura 14. Límite máximo de velocidad 30 km/h.	18
Figura 15. Desafíos del sistema ADAS hacia la seguridad activa.	21
Figura 16. Esquema del algoritmo de reconocimiento de señales de tránsito de tipo regulatorias del Ecuador.	24
Figura 17. Diagrama de bloques funcional de un sistema ATSDR.	27
Figura 18. Ejemplo de diferentes factores que dificultan la clasificación y reconocimiento automático de las señales de tránsito: (a) desvanecimiento del color, (b) desorientación, (c) oclusión, (d) desenfoco de movimiento, (e) baja iluminación y (f) alta iluminación en la señal de tránsito.	29
Figura 19. Análisis de un pictograma particionado en 16 bloques.	32
Figura 20. Esquema del algoritmo de reconocimiento de señales de tránsito de tipo regulatorias del Ecuador basado en HOG y ELM.	39
Figura 21. Fases de la etapa de pre-procesamiento.	41

Figura 22. Histograma de imagen 20km/h en escala de grises en baja iluminación.	41
Figura 23. Histograma de imagen 20km/h en escala de grises, redimensionada 32x32 y ecualizada.	43
Figura 24. Cálculo del descriptor HOG de una señal de tránsito.....	43
Figura 25. Intensidad de cada pixel de imagen en escala de grises.	44
Figura 26. Procedimiento para el cálculo de los histogramas.....	45
Figura 27. Resultado del cálculo de histogramas de orientación.....	46
Figura 28. Gradiente asociado al intervalo del rango de orientaciones.	46
Figura 29. División en bloques y concatenación.	47
Figura 30. Esquema de algoritmo para multclasificación de señales de tránsito.	49
Figura 31. Estructura del modelo de una SLFN.	50
Figura 32. Consulta en un árbol Kd.	52
Figura 33. Diagrama de flujo multclasificación de señales regulatorias.	55
Figura 34. Diagrama de flujo multclasificación de señales de límite de velocidad máxima.....	56
Figura 35. Número de neuronas en la capa oculta vs tiempo de entrenamiento ELM.....	59
Figura 36. Curvas ROC para algoritmos de clasificación: (a) señales regulatorias (pare, ceda el paso y velocidad) con Kd-tree, SVM y ELM (b) señales de límite de velocidad con Kd-tree, SVM y ELM.....	61

RESUMEN

En el presente proyecto se desarrolla un algoritmo de reconocimiento de señales de tránsito de velocidad en condiciones extremas de iluminación en el espectro visible, utilizando visión por computadora e inteligencia artificial, al ingresar la imagen de la señal de tránsito, inicialmente se realiza un preprocesamiento de la imagen para mejorar la calidad de la misma y evitar la variación de iluminación, para luego utilizar el método de extracción de características HOG y utilizar su resultado en el algoritmo de multclasificación ELM. El algoritmo se entrenó y evaluó sobre una base de datos de señales de tránsito regulatorias (pare, ceda el paso y velocidad) del Ecuador con 17.437 muestras positivas y 30.000 muestras negativas, obteniendo una exactitud de 99,85%, sensibilidad de 99,78% y tiempo de procesamiento de 1,0574 ms, para la clasificación de señales de límite de velocidad se utilizó 15.694 muestras positivas y se obtuvo una exactitud de 96,71%, sensibilidad de 94,16% y tiempo de procesamiento de 6,8223 ms, en total el tiempo de procesamiento de todo el algoritmo alcanzo 8,2087 ms y se comparó con otros algoritmos de aprendizaje de máquina como SVM y Kd-tree utilizando curvas ROC, con su parámetro AUC y tiempos de procesamiento para determinar cuál de los algoritmos tienen mejor desempeño en aplicaciones ADAS en tiempo real.

Palabras Clave

- **SEÑALES DE TRÁNSITO**
- **ECUADOR**
- **ILUMINACIÓN EXTREMA**
- **HOG**
- **ELM**

ABSTRACT

In this project, an algorithm for recognizing speed traffic signs in extreme lighting conditions in the visible spectrum is developed, using computer vision and artificial intelligence, when the traffic signs image is input, initially a preprocessing of the image is carried out to improve the image quality and avoid the variation of illumination, to then use the HOG feature extraction method and use its result in the ELM multiclassification algorithm. The algorithm was trained and evaluated on a database of regulatory traffic signs (stop, yield step and speed) of Ecuador with 17,437 positive samples and 30,000 negative samples, obtaining an accuracy of 99.85%, sensitivity of 99.78 % and processing time of 1.0574 ms, for the classification of speed limit signs, 15,694 positive samples were used and an accuracy of 96.71%, sensitivity of 94.16% and processing time of 6.8223 ms were obtained, in total the processing time of the whole algorithm reached 8,2087 ms and was compared with other machine learning algorithms such as SVM and Kd-tree using ROC curves, with its AUC parameter and processing times to determine which of the algorithms have better performance in ADAS applications in real time.

Keywords

- **TRAFFIC SIGNS**
- **ECUADOR**
- **EXTREME LIGHTING**
- **HOG**
- **ELM**

CAPÍTULO I

1. INTRODUCCIÓN

1.1 Antecedentes

Según la Organización Mundial de la Salud (OMS), los accidentes de tránsito se encuentran entre las 20 principales causas de muerte a nivel mundial en el año 2015, con el 2,4% del total de muertes, siendo el motivo más común la falta de concentración frente al volante o conducir a exceso de velocidad. Cada año, los accidentes de tránsito causan la muerte de aproximadamente 1,25 millones de personas en todo el mundo donde el 48% de las muertes ocurren en personas de entre 15 y 44 años. El riesgo de que un peatón adulto muera tras ser atropellado por un automóvil es de menos del 20% a una velocidad de 50 km/h, y de cerca del 60% a 80 km/h (OMS, 2017), por lo que es fundamental para los conductores tener en cuenta la velocidad establecida por las señales de tránsito.

Al conducir dentro de un entorno urbano se requiere de concentración constante, lo que puede resultar estresante para el conductor y puede terminar con fatiga visual. Para ayudar al conductor, en los últimos años, se ha prestado una gran atención al desarrollo de Sistemas Avanzados de Asistencia al Conductor ADAS (Advanced Driver Assistance System) (John, Yoneda, Lui, & Mita, 2014), se desarrollan ADAS con el objetivo de mejorar la seguridad del automóvil y la comodidad al momento de conducir. Algunos de los componentes incluyen sistemas de navegación que proporcionan direcciones, así como información actualizada sobre el tráfico y sistemas basados en visión, como sistemas de advertencia de salida de carril y Reconocimiento de Señales de Tránsito TRS (Traffic Sign Recognition) (Zaklouta & Stanciuslescu, 2014).

El TRS es una parte esencial de un Sistema de Asistencia al Conductor (DAS), ya que proporciona a los conductores información de seguridad (Zaklouta & Stanciulescu, 2011). Con toda la información que se maneja en tiempo real se desarrollan vehículos autónomos, los cuales deben registrar la menor cantidad de

errores para su correcto funcionamiento. (Lilo Castellano, Mora Jimenez, Figuera Pozuelo, & Rojo Alvarez, 2014).

En la actualidad ya existen accidentes registrados en vehículos autónomos, como es el caso de uno de los fabricantes más grandes de vehículos autónomos Tesla Motors el cual tuvo un accidente fatal en una de sus creaciones (Boudette, 2017), uno de los factores con mayor influencia en los fallos en TRS son las condiciones de iluminación, en este sentido es necesario emplear técnicas que permitan interpretar la información visual de manera automática en condiciones de iluminación variable, que faciliten resaltar los episodios que pasan desapercibidas debido a descuido o falta de información, siendo la mejor opción el uso de técnicas de Visión por Computador e Inteligencia Artificial (Hoang, Koide, & Yamamoto, 2015).

1.2 Accidentes de tránsito en el Mundo y en el Ecuador

Los informes presentan que: “Las lesiones causadas por accidentes de tránsito causan más de 1,2 millones de muertes al año a nivel mundial. Son la principal causa de muerte entre los jóvenes de entre 15 y 29 años, y les cuesta a los gobiernos aproximadamente el 3% del PIB” (World Health Organization, 2017). A pesar de tener tanto impacto y de que en muchos casos pueden ser prevenidos, las acciones para combatir este desafío global han sido insuficientes.

1.2.1 Accidentes de tránsito en el Mundo

El tercer informe mundial sobre el estado de la seguridad vial, muestra que los países de ingresos bajos y medianos son los que tienen un mayor número de accidentes de tránsito, con el doble de las tasas de mortalidad de los países de altos ingresos y el 90% de las muertes mundiales por accidentes de tránsito (World Health Organization, 2017), esto debido a que las economías emergentes tienen un rápido crecimiento económico por lo cual existe una rápida urbanización y motorización.

Muchos países de altos ingresos han logrado romper el vínculo entre el aumento de la motorización y las muertes ocasionadas por el tránsito, y algunos logran reducir drásticamente esas muertes. Estos logros son el resultado de una infraestructura más segura, la mejora de la seguridad de los vehículos y la implementación de varias otras intervenciones que se sabe son eficaces para reducir los traumatismos causados por el tránsito (World Health Organization, 2017), dentro de la mejora en la seguridad de los vehículos se encuentran los ADAS.

En el 2015, lesiones causadas por el tránsito llegaron a ser la décima causa de muerte en todos los grupos de edad a nivel mundial (Véase **Tabla 1**), y se prevé que se convertirán en la séptima causa de muerte para 2030 (World Health Organization, 2017).

Tabla 1.

Las 20 causas principales de muerte a nivel mundial 2015.

Rank	Causas	Muertes (000`s)	% de muertes total
0	Todas las Causas	56.441	100,0
1	Enfermedad isquémica del corazón	8.756	15,5
2	Ataque fulminante	6.241	11,1
3	Infecciones respiratorias bajas	3.190	5,7
4	Enfermedad pulmonar obstructiva crónica	3.170	5,6
5	Tráquea, bronquios, cánceres de pulmón	1.695	3,0
6	Diabetes mellitus	1.586	2,8
7	Enfermedad de Alzheimer y otras demencias	1.542	2,7
8	Enfermedades diarreicas	1.389	2,5
9	Tuberculosis	1.373	2,4
10	Accidentes de Tránsito	1.342	2,4

Fuente: (World Health Organization, 2017)

En el año 2013 hubo 1,25 millones de muertes por accidentes de tránsito, una cifra que se ha estancado desde el año 2007. El aumento de la población del 4% entre 2010 y 2013 y un aumento del 16% en vehículos matriculados durante el mismo período como se puede observar en la **Figura 1**, sugiere que los esfuerzos para frenar el aumento de las muertes en el tránsito pueden haber evitado el crecimiento de las estadísticas (World Health Organization, 2017).




Figura 1. Número de muertes por accidentes de tránsito en el mundo, 2013.

Fuente: (World Health Organization, 2017)

En septiembre de 2015, las Naciones Unidas lanzaron la Agenda 2030 para el Desarrollo Sostenible: el marco de desarrollo que reemplaza y se basa en los logros de los Objetivos de Desarrollo del Milenio. La seguridad vial estaba ausente de los Objetivos de Desarrollo del Milenio, pero los objetivos de seguridad vial se han integrado en la nueva Agenda 2030 (World Health Organization, 2017).

Los dos objetivos que se propusieron dentro de los objetivos de desarrollo sostenible respecto a la seguridad vial son los siguientes:

- Para 2020, “reducir a la mitad el número de muertes y lesiones a nivel mundial por accidentes de tránsito” (World Health Organization, 2017).
- Para 2030, “proporcionar acceso a sistemas de transporte seguros, asequibles, accesibles y sostenibles para todos, mejorando la seguridad vial, especialmente ampliando el transporte público, prestando especial atención a las necesidades de las personas vulnerables, mujeres, niños, personas con discapacidad y personas mayores” (World Health Organization, 2017).

1.2.1.1 Factores de riesgo en accidentes de tránsito

Los factores de riesgo en accidentes de tránsito a nivel mundial son clasificados según (World Health Organization, 2017) de la siguiente manera:

- **El enfoque de sistemas de seguridad (tener en cuenta el error humano):** Este enfoque centraliza al ser humano, teniendo en cuenta su vulnerabilidad y reconoce que los sistemas de seguridad deben tolerar errores humanos.
- **Aceleración:** Se relaciona directamente a la velocidad del conductor “un incremento de 1 km/h de la velocidad media del vehículo se traduce en un aumento del 3% en la incidencia de accidentes con lesiones, y un 4% a 5% en la incidencia de accidentes mortales” (World Health Organization, 2017), esto nos demuestra que mientras mayor velocidad media tengamos establecida mayor es la probabilidad de accidentes de tránsito.
- **Conducción bajo los efectos del alcohol u otras sustancias psicoactivas:** Conducir bajo los efectos del alcohol, cualquier sustancia psicoactiva o droga aumenta el riesgo de un accidente con desenlace fatal o lesiones graves. Al conducir bajo los efectos de drogas, el riesgo de accidente de tránsito aumenta en diversos grados en función de la sustancia psicoactiva. Por ejemplo, “el riesgo de accidente mortal de un consumidor de anfetaminas es unas cinco veces mayor que el de uno que no consume drogas” (World Health Organization, 2017).

- **No utilización de cascos, cinturones de seguridad y sistemas de sujeción para niños:** Usar correctamente un casco de motociclista puede reducir el riesgo de muerte casi en un 40%, y el riesgo de lesiones graves en más del 70%. El uso del cinturón de seguridad disminuye entre un 40% y un 50% el riesgo de muerte de los ocupantes delanteros de un vehículo, y entre un 25% y un 75% el de los ocupantes de asientos traseros.
- **Conducción distraída** Existen muchos tipos de distracciones que pueden alterar la conducción, pero uno de los factores que preocupan de mayor manera actualmente es el uso de teléfonos móviles que actualmente causan una gran cantidad de accidentes.
- **Infraestructura vial insegura:** El trazado vial puede afectar considerablemente a la seguridad. Teóricamente, todas las vías se deberían concebir teniendo en cuenta la seguridad de todos los usuarios. Esto supondría velar por que hubiera servicios adecuados para peatones, ciclistas y motociclistas. Las aceras, los carriles para bicicletas, los cruces seguros y otras medidas de ordenamiento del tránsito son de vital importancia para reducir el riesgo de lesiones entre los usuarios.
- **Vehículos inseguros:** Se pueden aplicar los reglamentos de las Naciones Unidas sobre la seguridad de los vehículos que están enfocados a los criterios de fabricación y producción estos pueden ayudar a salvar muchas vidas. Los reglamentos exigen que los fabricantes de vehículos cumplan normas relativas a impactos frontales y laterales, incluyan el control electrónico de estabilidad (para prevenir el sobre viraje) y aseguren que todos los vehículos tengan airbags y cinturones de seguridad. Estas solo son algunas de las normas básicas, además de ello deberían considerar implementar como norma utilizar ADAS para mejorar la seguridad de los vehículos.
- **Atención inapropiada tras el accidente**
Se debe ser efectivo y no tener demoras para detectar lesiones y prestar asistencia a las víctimas de un accidente de tránsito, ya que puede aumentar la gravedad de las lesiones mientras pasa el tiempo.

- **Cumplimiento insuficiente de las normas de tránsito**

La aplicación de la normativa se basa en establecer, actualizar periódicamente y aplicar normas de prevención para los factores de riesgo ya mencionados, a nivel nacional municipal y local, incluyendo también las sanciones a aplicarse sobre su incumplimiento.

1.2.1.2 Accidentes de Tránsito debido al exceso de velocidad

Un peatón adulto tiene menos de un 20% de posibilidades de morir si es atropellado por un automóvil a menos de 50 km / h, pero casi un 60% de riesgo de morir si lo golpea a 80 km / h (World Health Organization, 2017). Como se puede observar en la **Figura 2** la mayor cantidad de países tienen un límite de velocidad en áreas urbanas de mayor o igual a 50 km/h, y es mucho más notorio en Sudamérica a excepción de países como Ecuador, Uruguay y Paraguay, en los cuales el límite de velocidad es menor o igual a 50 km/h colocándolos en un lugar más seguro relativamente.




Figura 2. Límites de velocidad en carreteras urbanas en el mundo.

Fuente: (World Health Organization, 2017)

1.2.2 Accidentes de tránsito en el Ecuador

Ecuador es un país con una gran cantidad de accidentes de tránsito fatales como se muestra en la **Figura 3**, Ecuador supera la tasa de muertes en accidentes de tránsito con un 3,14% sobre la media de los países de la región andina. En el Ecuador los accidentes de tránsito son un problema constante, que se presenta debido a varios factores críticos, entre los más importantes se encuentran la imprudencia de los conductores al conducir en exceso de velocidad (10 hasta 100 km/h) y la imprudencia de los conductores al no respetar las señalizaciones de tránsito (Agencia Nacional de Tránsito, 2017).




Figura 3. Tasa de muertes por accidentes de tránsito en la Región Andina 2013.

Fuente: (Agencia Nacional de Tránsito, 2017)

En los meses de Enero y Febrero del 2017, en (Agencia Nacional de Tránsito, 2017) se registraron los siguientes casos de siniestros:

- En primer lugar 874 casos, debido a conducir desatento a las condiciones de tránsito, siendo el 18,21% del total.
- En segundo lugar, se registran 636 casos, debido a conducir vehículo superando los límites máximos de velocidad, siendo el 13,25 % del total.
- En tercer lugar, se registran 610 casos, debido a no respetar las señales reglamentarias de tránsito (pare, ceda el paso, luz roja del semáforo, etc.), siendo el 12,71 % del total.

1.2.2.1 Accidentes de tránsito en los últimos años

Las estadísticas analizadas por año están determinadas desde el año 2008 hasta el año 2016, mientras que del año 2017 están detalladas mensualmente, por lo cual se detalla las estadísticas anuales en el período: 2008 – 2016, para el análisis y comparación del año 2017 serán tomadas las estadísticas mensualmente.

En el período: 2008 - 2016 que se muestra en la **Figura 4** se puede determinar que: el número de accidentes de tránsito durante el año 2016 disminuyó en un 15,2% con respecto al 2015, y un 21,7% con respecto al año 2014, aunque aumento un 3,96% respecto al 2013 y similarmente respecto a años anteriores (INEC, 2016). Es decir que en los últimos años debido a la motorización que se desarrolla en el país hay una mayor tasa de accidentes de tránsito cada año y con la ayuda de leyes, personal y tecnología se intenta disminuir estas estadísticas.




Figura 4. Número de accidentes de tránsito en el país. Período: 2008-2016.

Fuente: (INEC, 2016)

En el año 2016 como se observa en la **Figura 5**, la provincia con mayor número de accidentes de tránsito por cada mil vehículos matriculados, fue Imbabura con 69 accidentes, superando con creces a las demás provincias debido a que la media

nacional se establece en 15 accidentes por cada mil vehículos matriculados, dentro de esta media se encuentra la provincia de Pichincha. Estas estadísticas fueron tomadas de un total nacional de 30.269 accidentes de tránsito (INEC, 2016).




Figura 5. Número de accidentes de tránsito en el país Año 2016.

Fuente: (INEC, 2016)

Del total de accidentes de tránsito registrados en el año 2016 como se muestra en la **Figura 6**, los choques, atropellos y estrellamientos, representan el 75,5%. Estas estadísticas fueron tomadas de un total nacional de 30.269 accidentes de tránsito año 2016 (INEC, 2016).

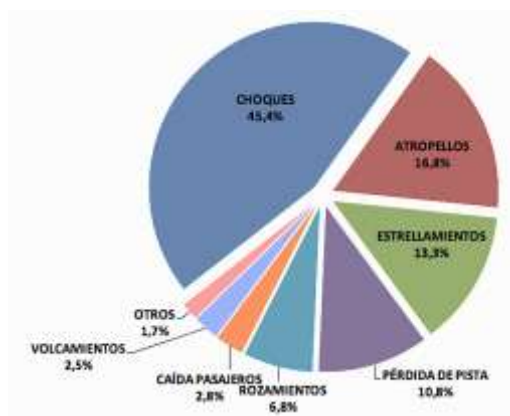


Figura 6. Distribución de accidentes de tránsito, según clase Año 2016.

Fuente: (INEC, 2016)

En el año 2016 como se muestra en la **Figura 7**, la impericia e imprudencia del conductor es la principal causa de los accidentes de tránsito, ya que de todas las causas representa el 51,9% del total de accidentes de tránsito. En segundo podemos observar que no respetar las señales de tránsito tiene un 13,4% del total de accidentes de tránsito y en tercer lugar muy similar al segundo se puede observar que el exceso de velocidad tiene un 12,4 %. Estas estadísticas fueron tomadas de un total nacional de 30.269 accidentes de tránsito año 2016 (INEC, 2016).

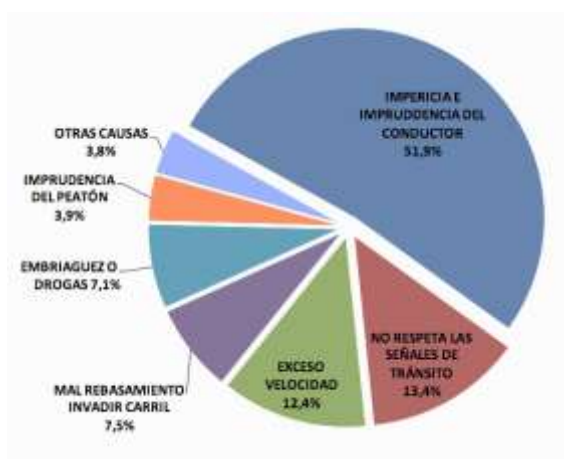


Figura 7. Distribución de accidentes de tránsito, según causa Año 2016.

Fuente: (INEC, 2016)

En el año 2016 como se muestra en la **Figura 8**, la impericia e imprudencia del conductor es la principal causa de personas heridas en accidentes de tránsito, registrando un 46,0% del total nacional, mientras que el exceso de velocidad está en segundo lugar con 15,94% y en tercer lugar se encuentra no respetar las señales de tránsito con un 14,88%. Entre estas tres causas se obtiene un 76,82%, determinando que estas deben ser tratadas con mayor énfasis para disminuir los heridos en accidentes de tránsito. Estas estadísticas fueron tomadas de un total nacional de 21.458 heridos en accidentes de tránsito año 2016 (INEC, 2016).




Figura 8. Número de heridos en accidentes de tránsito, según causa Año 2016.

Fuente: (INEC, 2016)

En el año 2016 como se muestra en la **Figura 9**, la impericia e imprudencia del conductor es la principal causa de personas fallecidas en accidentes de tránsito, registrando un 56,3% del total nacional, mientras que en segundo lugar se ubica el exceso de velocidad con un 13,17% del total nacional y en tercer lugar se ubica imprudencia del peatón con el 8,34% del total nacional. Estas estadísticas fueron tomadas de un total nacional de 1.967 muertos en accidentes de tránsito año 2016 (INEC, 2016).




Figura 9. Número de muertos en accidentes de tránsito, según causa.

Fuente: (INEC, 2016)

Desde enero del 2016 a octubre del 2017 se tienen datos de los siniestros de tránsito como se muestra en la **Figura 10**, la tendencia de los siniestros de tránsito muestra que va en descenso, pero también se muestra que en los meses donde más se producen los siniestros son enero y diciembre por lo cual se esperaría que la línea de tendencia sea a final del año paralela al eje, mostrando constante la cantidad de siniestros en los últimos años. Desde enero hasta octubre del 2017 el mes con menor cantidad de siniestros de tránsito fue marzo con 2.323 y el que tuvo una mayor cantidad fue julio con 2.471 (Agencia Nacional de Tránsito, 2017).




Figura 10. Serie cronológica siniestros de tránsito enero 2016 a octubre 2017.

Fuente: (Agencia Nacional de Tránsito, 2017)

Desde enero hasta octubre del 2017 las causas probables de accidentes de tránsito a nivel nacional detalladas en **Tabla 2**, nos muestran las cuatro causas detalladas con mayor número de siniestros y la cantidad de lesionados y fallecidos en cada una de estas causas. Entre las principales tenemos en primer lugar conducir desatento a las condiciones de tránsito con un 16,27%, en segundo lugar, conducir vehículo superando los límites máximos de velocidad con un 14,29% y en tercer lugar no respetar las señales reglamentarias de tránsito con un 13,67%. Entre estas principales causas se engloba un 44,23%, acercándose a ser la mitad del total de los siniestros, por lo que deben ser muy tomados en cuenta para disminuir estas estadísticas. Estas estadísticas

fueron tomadas de un total nacional de 23.963 siniestros de tránsito año 2017 (Agencia Nacional de Tránsito, 2017).

Tabla 2.

Causas probables de accidentes de tránsito a nivel nacional de enero hasta octubre 2017.

Causas Probables	Siniestros	Lesionados	Fallecidos
Conducir desatento a las condiciones de tránsito (celular, pantallas de video, comida, maquillaje o cualquier otro elemento distractor).	3.899	2.943	353
Conducir vehículo superando los límites máximos de velocidad.	3.425	3.095	316
No respetar las señales reglamentarias de tránsito. (pare, ceda el paso, luz roja del semáforo, etc.).	3.282	2.512	66
No mantener la distancia prudencial con respecto al vehículo que le antecede.	2.181	1.576	154
Otros	11.176	8.157	880
Total	23.963	18.283	1.769

Fuente: (Agencia Nacional de Tránsito, 2017)

En el mes de octubre del 2017 como se muestra en la **Tabla 3**, los siniestros según el día y la hora de ocurrencia a nivel nacional, nos muestra que las horas donde existe una mayor cantidad de accidentes de tránsito con de 7:00 - 07:59 con un total de 144, en la tarde de 13:00 a 13:59 con un total de 132, en la noche de 18:00 a 18:59 con un total de 150 y de 19:00 a 19:59 con un total de 163, siendo este último el intervalo donde existe una mayor cantidad de accidentes de tránsito. Estos datos fueron tomadas de un total nacional de 2.431 siniestros de tránsito año 2017 mes octubre (Agencia Nacional de Tránsito, 2017). Se observa que existe una gran cantidad de accidentes en la noche a pesar de no existir una gran cantidad de tránsito como en el día y una de las mayores cantidades de siniestros ocurren en el día cuando la iluminación es excesiva, por lo que se determina que la influencia de la iluminación es fundamental en los accidentes de tránsito, ya que la poca iluminación en la noche y el exceso de iluminación en el día afectan directamente en el aumento de siniestros de tránsito.

Tabla 3.

Siniestros según día y hora de ocurrencia a nivel nacional - octubre 2017.

RANGO HORA	LUNES	MARTES	MIÉRCOLES	JUEVES	VIERNES	SÁBADO	DOMINGO	TOTAL
00:00 A 00:59	6	11	5	8	7	12	19	69
01:00 A 01:59	6	4	3	7	7	16	22	65
02:00 A 02:59	3	2	3	5	3	13	23	52
03:00 A 03:59	4	2	3	7	9	17	28	70
04:00 A 04:59	5	2	1	3	6	20	22	59
05:00 A 05:59	6	6	5	5	11	10	26	69
06:00 A 06:59	17	20	12	17	15	12	22	115
07:00 A 07:59	19	31	20	18	19	20	17	144
08:00 A 08:59	16	19	16	18	14	9	15	107
09:00 A 09:59	11	15	12	10	11	9	18	86
10:00 A 10:59	15	24	9	15	21	17	21	122
11:00 A 11:59	22	9	5	10	10	19	18	93
12:00 A 12:59	25	17	15	13	18	18	14	120
13:00 A 13:59	25	14	23	16	21	10	23	132
14:00 A 14:59	17	23	14	11	15	20	23	123
15:00 A 15:59	20	23	13	11	10	19	24	120
16:00 A 16:59	20	12	17	12	15	14	17	107
17:00 A 17:59	13	14	12	18	21	15	17	110
18:00 A 18:59	27	28	15	13	15	26	26	150
19:00 A 19:59	22	28	17	14	25	27	30	163
20:00 A 20:59	11	15	8	10	26	22	25	117
21:00 A 21:59	12	13	8	5	13	25	15	91
22:00 A 22:59	11	9	5	5	9	21	13	73
23:00 A 23:59	6	7	11	10	11	22	7	74
	339	348	253	261	332	413	485	2431

Fuente: (Agencia Nacional de Tránsito, 2017)

A nivel nacional la mayor cantidad de accidentes de tránsito son producidos por conducir desatento a las condiciones de tránsito, conducir vehículo superando los límites máximos de velocidad y no respetar las señales reglamentarias de tránsito. Estas tres causas pueden ser atenuarse implementando sistemas electrónicos que asistan al conductor para mejorar su atención y ayudar a que respete la señalización y los límites de velocidad. Además, la influencia de las condiciones externas como la variación de iluminación afectan directamente en la cantidad de accidentes de tránsito por lo que es un tema importante a tratar para disminuir los accidentes de tránsito.

1.3 Tipos de señales de tránsito en el Ecuador

Las señales de tránsito son: dispositivos de control de tránsito, que informan a los usuarios de las regulaciones y dan prevención y guías necesarias para la operación segura uniforme y eficiente de todos los elementos del flujo de tránsito, tienen el propósito de regular, prevenir o guiar a los usuarios viales (INEN, 2011).

De la clasificación de las señales de tránsito mostradas en la **Figura 11**, las señales con mayor relevancia que están dentro de las señales verticales son: señales de reglamentación, señales de prevención y señales de información. (Agencia Nacional de Tránsito, 2017).

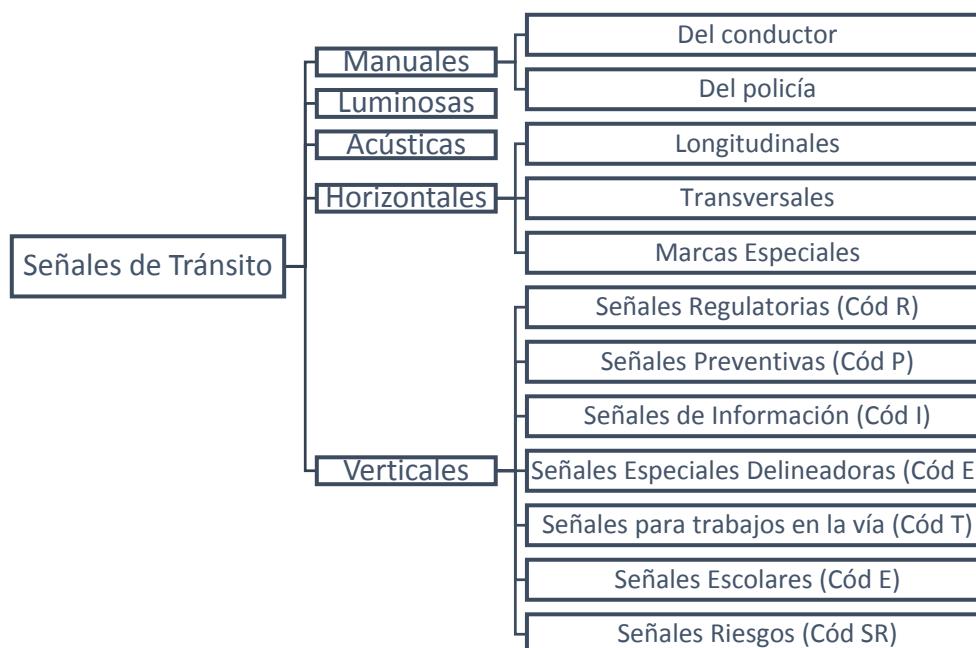


Figura 11. Clasificación de señales de tránsito del Ecuador.

Fuente: (INEN, 2011)

Las principales señales de tránsito se muestran en la **Figura 12**, los detalles de cada clase son los siguientes:

- **Señales Regulatorias:** Indican la existencia de prohibiciones, restricciones en el uso de caminos, son generalmente rectángulos de fondo blanco, símbolo negro debajo de un círculo rojo, también tienen fondo negro y letras blancas (Agencia Nacional de Tránsito, 2017). De estas señales las de mayor importancia son objetivo del reconocimiento: señal de pare, ceda el paso y señales de límite máximo de velocidad.
- **Señales de Prevención:** Tienen por objeto advertir la existencia de un peligro y la naturaleza de este. Tienen las siguientes características: fondo

tráfico de la vía principal. Su objetivo es indicar a los conductores que deben ceder el paso a los vehículos que circulan por la vía a la cual se aproximan sin necesidad de detenerse, siempre y cuando tienen el espacio suficiente para cruzarla o incorporarse con seguridad.




Figura 13. Serie de prioridad de paso: a) señal pare, b) ceda el paso.

Fuente: (INEN, 2011)

1.3.2 Serie de límites máximos

Límite máximo de velocidad: Se utilizan para indicar la velocidad máxima permitida en un tramo de vía, cuando dicho límite difiere de los establecidos en la Ley Orgánica de Transporte Terrestre Tránsito y Seguridad Vial, su instalación requiere de un estudio previo de dicho tramo, que considere: tipo de vía, velocidad de diseño y de operación, la accidentalidad registrada, el uso del suelo del sector adyacente, entre otros (INEN, 2011).



Figura 14. Límite máximo de velocidad 30 km/h.

Fuente: (INEN, 2011)

1.4 Sistemas inteligentes de transporte

Los sistemas inteligentes de transporte (ITS, por sus siglas en inglés Intelligent Transportation Systems), según el departamento de transporte de los Estados Unidos de América se define como: “Un sistema que aplica procesos electrónicos de comunicación e información, por separado o integrado, para mejorar la eficiencia o seguridad de los sistemas de transporte terrestre ” (Intelligent transportation system architecture and standards, 2008). Se considera como parte del Internet de las Cosas (IoT, Internet of things) (Getting the data quality from IoT, 2017).

Un concepto más amplio del término ITS es el que define el Instituto Europeo de Normas de Telecomunicaciones (ETSI, por sus siglas en inglés European Telecommunications Standards Institute), como “la aplicación de las TICS en los sistemas de gestión, infraestructura y medios de transporte. El término incluye los sistemas de comunicaciones que se utilizan entre la infraestructura de transporte y medios multimodales, como también los sistemas de comunicación utilizados en los medios de transporte entre sí” (CINTEL, 2010).

De acuerdo a ITS América (CINTEL, 2010), los sistemas inteligentes de transporte se clasifican en cinco áreas funcionales:

- **Sistemas Avanzados de Gestión de Tráfico (ATMS, por sus siglas en inglés Advanced Traffic Management Systems):** Encargados de detectar situaciones de tráfico y los transmite al centro de control a través de redes de comunicaciones, para luego desarrollar estrategias de control del tráfico mediante el análisis de los datos recolectados.
- **Sistemas Avanzados de Información para Viajeros (ATIS, por sus siglas en inglés Advance Traveler Information System):** Estos sistemas hacen uso de tecnologías avanzadas para permitir a los usuarios obtener información sobre vías y/o carreteras en tiempo real, en cualquier lugar. Este tipo de sistemas incluyen principalmente señales intercambiables de mensajes, radio asesor de carretera (HAR), sistemas de georreferenciación satelital (GPS), entre otros.

- **Sistemas Avanzados de Control y Seguridad de Vehículos (AVCSS, por sus siglas en inglés Advanced Vehicle Control and Safety Systems):** Aplican tecnologías avanzadas en vehículos y carreteras con el fin de reducir accidentes y mejorar la seguridad del tránsito, además ayudan a los conductores a controlar sus vehículos. Se incluye principalmente: alerta y control anti-colisión, asistencia al conductor (ADAS), control lateral y longitudinal automático, y a largo plazo la implementación de conducción automática y sistemas automáticos en carreteras.
- **Operaciones de vehículos comerciales (CVO, por sus siglas en inglés Commercial Vehicle Operations):** Aplica tecnologías ATM, ATIS y AVCSS en la operación de vehículos comerciales, tales como: taxis, buses, ambulancias con el fin de mejorar la eficiencia y seguridad del tránsito.
- **Sistemas Avanzados de Transporte Público (APTS, por sus siglas en inglés Advanced Public Transportation Systems):** Aplica la tecnología de ATMS, ATIS y AVCSS en el transporte público con el fin de mejorar la calidad de servicio, y aumentar la eficiencia y número de personas que hacen uso del transporte público. Estos sistemas incluyen principalmente vigilancia automática de vehículos (VPS), boletos electrónicos, entre otros.

1.4.1 Sistemas avanzados de asistencia a la conducción

Los sistemas avanzados de asistencia a la conducción (ADAS, por sus siglas en inglés Advanced Driver Assistance Systems) tienen el objetivo de mejorar la seguridad del automóvil y la comodidad al momento de conducir. Algunos de los componentes incluyen sistemas de navegación que proporcionan direcciones, así como información actualizada sobre el tráfico y sistemas basados en visión, como sistemas de advertencia de salida de carril y reconocimiento de señales de tránsito (TRS, por sus siglas en inglés Traffic Sign Recognition) (Zaklouta & Stanciuslescu, 2014) como se muestra en la *Figura 15*.



Figura 15. Desafíos del sistema ADAS hacia la seguridad activa.

Fuente: (Hoang, Koide, & Yamamoto, 2015)

1.4.1.1 Sistemas de reconocimiento de señales de tránsito

Los sistemas de reconocimiento de señales de tránsito se encuentran dentro de los ADAS, esta tecnología tiene una aplicación pasiva y activa (Cruzado Hernando, 2015).

- **Aplicación pasiva:** Consiste en advertir al conductor mediante una señal acústica o visual que está infringiendo una limitación de velocidad, que entra en zona de curvas peligrosas, que pare, que ceda el paso, etc. La obligación del conductor es leer todas las señales, pero puede ser de ayuda en caso de una distracción o en baja visibilidad.
- **Aplicación activa:** Consiste en que el sistema interviene para evitar un accidente. Por ejemplo, en el caso que se esté circulando a 50 km/h y el sistema identifica una señal de pare, el sistema interpreta que el conductor no va a parar, ordenará activar los frenos para ayudar a evitar un posible accidente, este sistema puede o no desconectarse voluntariamente.

Un sistema asistente con capacidad de reconocimiento de limitación de velocidad puede informar a los conductores sobre el cambio en el límite de velocidad, así como notificarles si superan el límite de velocidad. Por lo tanto, las tareas cognitivas del

conductor se pueden reducir y se puede llegar a una conducción más segura (Hoang, Koide, & Yamamoto, 2015).

Mobileye (Mobileye, 2017), Continental AG (Continental, 2018), BMW (BMW Group, 2016) y Mercedes-Benz (Mercedes-Benz, 2013) han desarrollado estos sistemas que detectan los límites de velocidad. La detección de la señal de tránsito se puede utilizar para advertir a los conductores sobre situaciones actuales de tráfico, cruces peligrosos y rutas de mayor afluencia de personas, como se muestra en la **Figura 15**.

1.5 Justificación e importancia

Los accidentes de tránsito siendo la décima causa de muerte en el mundo (World Health Organization, 2017) y siendo Ecuador uno de los países con una tasa de muertes en accidentes de tránsito que sobrepasa a la de varios países de la región andina como Bolivia, Perú y Colombia (Agencia Nacional de Tránsito, 2017), demuestra que esta problemática debe ser un muy importante tema de investigación, se debe abordar para tratar de mitigar el crecimiento de accidentes y muertes causadas por los accidentes de tránsito.

A pesar de que en el año 2016 el número de accidentes de tránsito disminuyó un 15,2 % comparado con el año 2015 (INEC, 2016), en lo que va del año 2017 se ha mantenido una tendencia de mantenerse casi sin disminución respecto al anterior año (Agencia Nacional de Tránsito, 2017), las causas probables de los accidentes de tránsito se mantienen en un orden casi invariante. Ubicando en primer lugar a conducir desatento a las condiciones de tránsito, en segundo lugar conducir un vehículo superando los límites de velocidad y en tercer lugar no respetar las señales reglamentarias de tránsito, siendo estas tres causas las generadoras de casi la mitad de las estadísticas de siniestros, lesionados y fallecidos del año 2017 (Agencia Nacional de Tránsito, 2017), por lo cual podemos determinar que ayudando a mejorar la atención del conductor, que el conductor mantenga la velocidad establecida y que

respete las señales reglamentarias de tránsito, principalmente las de mayor relevancia como pare, ceda el paso, se logrará disminuir las estadísticas de accidentes de tránsito, con la ayuda de ADAS que cumplan con estos parámetros, los componentes principales en este caso serían TRS que se manejen en tiempo real, para asistir a los conductores con información actualizada sobre las señales de tránsito y generar advertencias o acciones sobre las mismas.

La existencia de una gran cantidad de accidentes en la noche, a pesar de no existir una gran cantidad de tránsito en ese horario, nos permite concluir que la falta de iluminación es un factor importante a tratar, además de una gran cantidad de accidentes de tránsito en el día en horarios donde la iluminación es excesiva (Agencia Nacional de Tránsito, 2017), nos permite deducir que la cantidad de iluminación es un tema muy importante a tratar, ya que en condiciones de iluminación extremas existe una mayor posibilidad de que se genere un accidente de tránsito.

Esta investigación se realiza con la finalidad de disminuir la cantidad de accidentes de tránsito en el Ecuador, aplicando tecnologías de visión por computadora e inteligencia artificial, por medio de reconocimiento de las principales señales regulatorias, que tengan un buen rendimiento y puedan acoplarse a diferentes sistemas con facilidad para ayudar en un futuro a generar ADAS muy robustos y eficientes, ayudando a disminuir las distracciones del conductor y que su enfoque sea una conducción más segura.

1.6 Alcance del proyecto

En el presente trabajo de investigación se propondrá diseñar e implementar un algoritmo para el reconocimiento de las señales regulatorias de tránsito de límite máximo de velocidad existentes en la red vial del Ecuador, empleando técnicas de visión por computador e inteligencia artificial.




Figura 16. Esquema del algoritmo de reconocimiento de señales de tránsito de tipo regulatorias del Ecuador.

En la **Figura 16**, se puede observar el esquema del algoritmo de reconocimiento de señales de tránsito de tipo regulatorias, inicialmente ingresa una imagen de una de las principales señal de transito de reglamentación (señal de pare, ceda el paso o límite máximo de velocidad), esta puede haber sido previamente extraída con algún método de generación de ROIs (regiones de interés), como métodos basados en color o en forma, estos son revisados con mayor detalle en la sección de detección de señales de tránsito de (Kaplan Berkaya, Gunduz, Ozsen, Akinlar, & Gunal, 2016). A la imagen de la ROI inicialmente se le realiza un pre procesamiento, con el objetivo de mejorar la información contenida en la misma y disminuir en la mayor cantidad posible los efectos de la iluminación variable o extrema en el espectro visible, que se puedan dar en casos como: día muy soleado, noche con muy poca luz, día nublado, amanecer.

Luego del pre procesamiento entra a una etapa de multiclasificación de las señales regulatorias, que utiliza un extractor de características modificado de HOG (histograma de gradientes orientado) más un clasificador basado en ELM (máquina de aprendizaje extremo), el cual diferencia la forma de la señal (octagonal de la señal de pare, triangular de la señal de ceda el paso o circular) y de esta clasificación se extrae las señales circulares que son las pertenecientes a las señales de límite máximo de velocidad, siendo estas la Salida 1.

En la siguiente etapa con las señales de límite máximo de velocidad (circulares) se procede a reconocer el tipo de señal de velocidad utilizando nuevamente una estructura HOG + ELM en la cual se utiliza el HOG previamente extraído al inicio del proceso, para finalmente obtener el tipo de señal de límite de velocidad máxima siendo esta la Salida 2.

Para medir la calidad de clasificación se utilizarán las curvas ROC (receiver operating characteristic) y el área bajo la misma AUC (area under the curve), estas curvas nos entregan una medida de rendimiento del sistema para determinar exactitud, precisión, eficiencia y comportamiento al realizar la clasificación de las señales de velocidad, mediante estas curvas se comparará con otros métodos de clasificación como: SVM (máquinas de vectores de soporte) y Kd-tree, determinando cuál de estos métodos genera mejores resultados, para finalmente desarrollar un algoritmo para el reconocimiento de señales de tránsito de límite máximo de velocidad y señales de pare y ceda el paso, que funcione en condiciones normales y extremas de iluminación en el espectro visible y que a futuro se pueda utilizar en el desarrollo de ADAS y de ITS en el Ecuador.

1.7 Objetivos

1.7.1 Objetivo general

- Diseñar e implementar un algoritmo para el reconocimiento de señales de tránsito regulatorias del Ecuador empleando visión por computador e inteligencia artificial en condiciones extremas de iluminación.

1.7.2 Objetivo específicos

- Desarrollar un algoritmo para el reconocimiento de señales de tránsito regulatorias del Ecuador, utilizando una versión modificada del descriptor HOG y el clasificador ELM.
- Desarrollar experimentos sobre una base de datos de señales de tránsito regulatorias de límites de velocidad del Ecuador.

- Verificar la calidad del algoritmo desarrollado usando curvas ROC y el índice AUC.

1.8 Estructura del documento

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

El capítulo 1 presenta la introducción al problema de los accidentes de tránsito a nivel mundial y en el Ecuador, las posibles causas de estos accidentes de tránsito, los tipos de señales de tránsito que se manejan en el Ecuador y los sistemas inteligentes de transporte.

El capítulo 2 presenta el estado del arte, en este capítulo se detalla algoritmos utilizados para el reconocimiento de señales de tránsito, divididos en extractores de características y clasificadores.

En el capítulo 3 presenta la metodología desarrollada para el reconocimiento de las más importantes señales de tránsito de reglamentación. Se detalla el método utilizado para la extracción de característica y la técnica utilizada para la clasificación de las señales de tránsito en condiciones de iluminación extrema en el espectro visible, resultado de la comparación del rendimiento de varios clasificadores sobre una versión modificada de HOG y un pre procesamiento, para conseguir los mejores resultados posibles.

El capítulo 4 presenta el análisis de resultados de la implementación de la metodología sobre una base de datos de señales de tránsito del Ecuador, en pruebas de funcionamiento en tiempo real sobre un ordenador y en condiciones de iluminación extrema en el espectro visible.

El capítulo 5 presenta las conclusiones del trabajo de titulación, incluyendo trabajos futuros que se pueden seguir desarrollando en este campo tan amplio de investigación.

CAPÍTULO II

2. ESTADO DEL ARTE

2.1 Introducción

Los sistemas de detección y reconocimiento automático de señales de tránsito (ATSDR, Automatic Traffic Sign Detection and Recognition), constituyen una tecnología fundamental para mantener informado al conductor en tiempo real sobre la normativa de la escena vial.

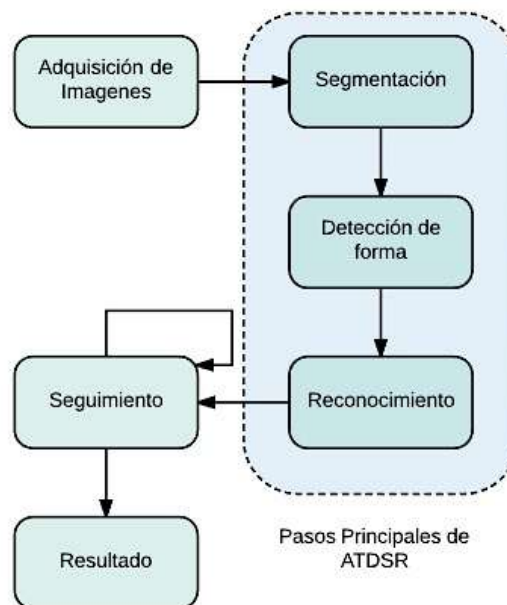


Figura 17. Diagrama de bloques funcional de un sistema ATSDR.

Fuente: (Gudigar, Chokkadi, & U, 2014)

El diagrama de bloques funcionales de un sistema ATSDR generalizado se muestra en la **Figura 17**. Las diferentes etapas de procesamiento de la ATSDR son:

- **Adquisición de imágenes:** una forma de capturar la escena de la carretera de forma continua con una configuración dada.
- **Segmentación:** localización de la región de interés (ROI), es decir, la señal de tránsito.

- **Detección de forma:** identificación de la región candidata a través de la clase de forma.
- **Reconocimiento:** el proceso de reconocimiento de la señal de tránsito se lleva a cabo en esta etapa.
- **Seguimiento:** asociación de señales de tránsito detectadas en una secuencia de imágenes.
- **Resultado:** Muestra los símbolos de las señales de tránsito detectados y reconocidos.

Como se puede observar en la **Figura 17**, la parte de segmentación, detección de forma y reconocimiento son de suma importancia para cualquier ATSDR, esta investigación se centra en la parte de *reconocimiento*.

La precisión juega un papel importante en el desarrollo de los ATSDR, ya que la clasificación errónea (falsos positivos y falsos negativos) pueden tener un impacto adverso en el conductor. Sin embargo, a pesar de que las señales de tránsito siguen los principios de diseño claro y se observan verticalmente de cara a la cámara, algunos factores pueden obstaculizar la efectividad de la detección y reconocimiento de las señales de tránsito (Gudigar, Chokkadi, & U, 2014). Algunos de ellos se detallan a continuación:

- **Desvanecimiento del color:** es el resultado de la exposición prolongada a la luz solar y la reacción de la pintura con el aire, el color de las señales de tránsito se desvanece con el tiempo.
- **Símbolos similares:** similitud entre los símbolos de las señales de tránsito.
- **Estandarización de los símbolos:** no existe una estandarización mundial de los símbolos en las señales de tránsito, estos varían según las leyes de los diferentes países.
- **Condiciones climáticas:** la visibilidad se ve afectada por las condiciones climáticas, como niebla, lluvia, nubes y el sol.
- **Objetos de colores similares:** presencia de objetos, que son similares en color y / o formas como edificios o vehículos.

- **Desorientación de las señales:** las señales pueden encontrarse desorientadas, dañadas u ocluidas.
- **Desenfoco de movimiento y vibración del automóvil:** la imagen a menudo sufre de un desenfoque de movimiento y vibración del automóvil, o en imágenes tomadas con cámaras sin estabilizador.
- **Información de color:** la información de color es muy sensible a las variaciones en el color claro del día, geometría de iluminación y geometría de visualización.
- **Sombras:** diferentes partes de la señal de tránsito están expuestas a diferentes niveles de iluminación.
- **Reflejo:** Sobre reflexión debido a la iluminación múltiple.

En la *Figura 18* se observan ejemplos de los problemas mencionados.




Figura 18. Ejemplo de diferentes factores que dificultan la clasificación y reconocimiento automático de las señales de tránsito: (a) desvanecimiento del color, (b) desorientación, (c) oclusión, (d) desenfoque de movimiento, (e) baja iluminación y (f) alta iluminación en la señal de tránsito.

Fuente: (Gudigar, Chokkadi, & U, 2014)


2.2 Reconocimiento de señales de tránsito

La etapa de reconocimiento, se basa en la identificación del pictograma o ideograma utilizado en cada símbolo de las señales de tránsito. En este proceso se clasifican las ROIs en las categorías a las que pertenece.

El reconocimiento de señales de tránsito recae en la clasificación de clases múltiples o multclasificación (Stallkamp, Schlipsing, Salmen, & Igel, 2012), (Greenhalgh & Mirmehdi, 2012). Las notaciones que se utilizan en las diferentes investigaciones relacionadas con el reconocimiento de señales de tránsito se encuentran detalladas en la **Tabla 4**.

Tabla 4.

Notaciones utilizadas en reconocimiento de señales de tránsito.

Nombre	Notación
No Especifica	NE
RBF	Función de Base Radial
K-d tree	Árbol K-dimensional
SIFT	Transformación de características de escala invariante
SURF	Características robustas aceleradas
BRISK	Binary robust invariant scalable keypoints
RANSAC	Random sample consensus
ANN	Red neuronal artificial
RF	Bosques aleatorios
Continúa 	

SVM	Máquina de vectores de soporte
kNN	K vecinos más cercanos
LCC	Codificación lineal restringida por localidad
CNN	Red neuronal convolucional
SOM	Mapa de autoorganización
SPM	Spatial pyramid matching
ELM	Máquina de aprendizaje extremo
MCDNN	Redes neuronales profundas multicanales
LPQ	Cuantificación de fase local
PCANet	Red de análisis de componentes principales
LBP	Patrones locales binarios
LDA	Análisis discriminante lineal
GTS	German Traffic Sign
HOG	Histograma de gradientes orientados

2.2.1 Método de intensidades de los píxeles de la imagen

Inicialmente, la ROI o la imagen debe pasar por un pre procesamiento para obtener el ideograma de la región en particular que contiene la información fundamental de la señal de tránsito, en estas regiones se consideran la información de las imágenes en binario o en escala de gris normalizadas. Los tamaños de las regiones son diferentes en diferentes técnicas como por ejemplo: 20 x 20 píxeles en (Eichner & Breckon, 2008), 25 x 25 píxeles en (Chiang, Chen, & Wang, 2010), 30 x 30 píxeles en (Nguwi

& Kouzani, 2008), 31x 31 píxeles en (Gudigar, Jagadale, P.K., & U., 2012) (Maldonado Bascón, Acevedo Rodríguez, Lafuente Arroyo, Fernández Caballero, & López-Ferreras, 2010). El tamaño al que se va a escalar está determinado por la resolución de la imagen y el costo computacional. En algunos documentos, se lo denomina Pixel of Interest (POI) o Region of Interest (ROI). El pictograma del signo se extrae al dividirlo en bloques, como se muestra en la **Figura 19**, para cada bloque, el vector se genera en función de las características del pictograma.



Figura 19. Análisis de un pictograma particionado en 16 bloques.

Fuente: (Gudigar, Chokkadi, & U, 2014)

2.2.2 Métodos de extracción de características

La extracción de características a partir de una imagen consiste en “la obtención de modelos matemáticos compactos que "resuman" el contenido de la imagen con el fin de simplificar el proceso de aprendizaje de los objetos a reconocer” (Universidad Autónoma de Barcelona, 2018). Dichas características son comúnmente llamadas descriptores. Los métodos más utilizados para el caso de las señales de tránsito son: SIFT en (Gao, Liu, Yu, & Li, 2014), (Zabihi, Zabihi, Beauchemin, & Bauer, 2017) y en (Malik & Siddiqi, 2014) se utiliza junto con SURF y BRISK, características invariantes en (Fleyeh & Dougherty, 2008) y (Gu, Yendo, Tehrani, Fujii, & Tanimoto, 2010), Haar wavelet en (Kuo & Lin, 2007) y mapa de Gabor en (Koncar, Janben, & Saman, 2007).

HOG se usa en (Zaklouta & Stanculescu, 2011), (Zaklouta & Stanculescu, 2014), (Fleyeh H. , 2015), (Kaplan Berkaya, Gunduz, Ozsen, Akinlar, & Gunal, 2016) , (Huang , Yu, Gu, & Liu, 2017) y (Zabihi, Zabihi, Beauchemin, & Bauer, 2017), para establecer la información respecto a la forma de los símbolos de la señal de tránsito,

ya que la distribución del gradiente de intensidad contribuye a definir la misma. Para fortalecer aún más las características, la información se combina utilizando HOG y LBP en (Yang, Qu, & Fang, 2012). Se combina HOG, LBP y Gabor en (Kaplan Berkaya, Gunduz, Ozsen, Akinlar, & Gunal, 2016). Del mismo modo, se utilizan tecnologías como: SIFT, HOG, LBP combinadas en (Guoqing Le, Xue Yuan, Jing Zhang, & HanSong Li, 2016), se concatenan usando LLC en (Zhu, Wang, Yao, & Bai, 2013). Para proporcionar el discernimiento entre las clases, las características de HOG se proyectan en sus componentes principales en (Stallkamp, Schlipsing, Salmen, & Igel, 2012) y los criterios de establecer los parámetros se utilizan para seleccionar el HOG se pueden observar con mayor detalle en (Zaklouta & Stanciuslescu, 2014).

2.2.3 Algoritmos de clasificación

En general, el sistema de reconocimiento se desarrolla utilizando clasificadores que como los siguientes: SVM en (Fleyeh & Dougherty, 2008), (Greenhalgh & Mirmehdi, 2012), (Aly, Deguchi, & Murase, 2013), (Zhu, Wang, Yao, & Bai, 2013), (Gomez & Bromberg, 2014), (Gao, Liu, Yu, & Li, 2014), (Fleyeh H. , 2015) y (Zabihi, Zabihi, Beauchemin, & Bauer, 2017), K-d tree en (Kuo & Lin, 2007) y (Zaklouta & Stanciuslescu, 2011), RF en (Zaklouta & Stanciuslescu, 2014), SOM en (Prieto & Allen, 2009) y Simboost una modificación de AdaBoost en (Ruta, Porikli, Watanabe, & Li, 2011), Redes neuronales artificiales en (Yin, Ouyang, Liu, & Wei, 2015) y (Shi & Lin, 2017).

Existen algoritmos de clasificación basados en aprendizaje profundo, estos algoritmos intenta asimilar representaciones de datos mediante el uso de arquitecturas (López, 2014) se utilizan en aplicaciones de TRS en: CNN se utiliza en (Ciresan, Meier, Masci, & Schmidhuber, 2011), MCDNN se utiliza en (Stallkamp, Schlipsing, Salmen, & Igel, 2012) y PCANet se utiliza en (Guoqing Le, Xue Yuan, Jing Zhang, & HanSong Li, 2016) es una red de aprendizaje profundo simple basado en la PCA, binary hashing y blockwise histograms.

2.3 Análisis de las técnicas utilizadas


Una recopilación de la información relevante sobre las técnicas más utilizadas en reconocimiento de señales de tránsito se presenta en **Tabla 5**, donde se detalla el tipo de descriptor que se utiliza, el algoritmo del clasificador, la base de datos, la medida de rendimiento, el tiempo de clasificación por imagen, la información se centra en reconocimiento de señales de tránsito con un mayor énfasis en señales de límite de velocidad.


Tabla 5.

Técnicas más relevantes utilizadas para el reconocimiento de señales de tránsito.

Referencia	Tipo de Descriptor	Algoritmo Clasificador	Base de datos utilizada	Medida de rendimiento	Tiempo de Clasificación por Imagen
(Kuo & Lin, 2007)	NE	RBF y K-d tree	NE	Exactitud: 95,5%	NE
(Malik & Siddiqi, 2014)	SIFT, SURF y BRISK	NE	Particular 172 imágenes, 32 clases, 5-6 imágenes por clase	Tasa de Reconocimiento SIFT 93,75%, SURF 81,25%, BRISK 87,5%	SIFT 9,03 s., SURF 17,63 s., BRISK 4,3 s.
(Zabihi, Zabihi, Beauchemin, & Bauer, 2017)	Información del Color y SIFT	Valor umbral y RANSAC	GTS	Exactitud: 88,9%	NE
(Wahyono & Jo, 2014)	HOG	ANN, kNN, SVM, RF	GTS 26.640 entrenamientos y 12.630 de prueba 43 clases 300 a 750 imágenes por clase	Exactitud: ANN 70,0% kNN 78,7% SVM 76,3% RF 76,5%	ANN 0,1656 s. kNN 0,1967 s. SVM 0,0408 s. RF 0,0094 s.
Continúa					



(Fleyeh & Dougherty, 2008)	Características invariantes introducidas por (Schulz-Mirbach, 1995)	SVM	Particular 600 imágenes binarias de 36x36 píxeles 350 de bordes de señales y 250 de señales de límite de velocidad	Rendimiento de clasificación 98% bordes de la señales y 93% señales de límite de velocidad	0,05 s.
(Zhu, Wang, Yao, & Bai, 2013)	LCC+SPM	SVM, CNN, multi-escala CNN, RF	GTS 26.640 entrenamientos y 12.569 de prueba 43 clases	Exactitud: LCC+SPM+SVM 99,67% CNN 99,46% multi-escala CNN 98,31% RF 96,14%	LCC+SPM+SVM 0,0325 s.
(Stallkamp, Schlipsing, Salmen, & Igel, 2012)	HOG 2	MCDNN, multi-escala CNN, RF, LDA	GTS 51.840 imágenes de la base de datos 43 clases	Exactitud señales de límite de velocidad: MCDNN 99,47% multi-escala CNN 98,62% RF+HOG2 95,95% LDA+HOG2 95,37%	NE
(Zaklouta & Stanculescu, 2014)	HOG	K-d tree, RF	GTS 14.763 entrenamientos y 1.584 de prueba	Exactitud: RF 97% K-d tree 88,73%	NE
Continúa					

(Greenhalg h & Mirmehdi, 2012)	HOG	SVM	GTS	Exactitud: 89,2%	NE
(Fleyeh H. , 2015)	HOG	SVM	Particular Imágenes de prueba 104	Exactitud: 98%	NE
(Aly, Deguchi, & Murase, 2013)	LPQ	SVM	GTS 26.640 entrenamie nto y 12.569 de prueba 43 clases	Exactitud en imágenes con desenfoco (falta de nitidez) debido al movimiento 90-65% con menor y mayor desenfoque	NE
(Zaklouta & Stanciulesc u, 2011)	HOG4	Kd-tree	Particular 11 clases entre 12 y 342 imágenes por clase	Exactitud: 92,7%	0,0179 s.
(Yin, Ouyang, Liu, & Wei, 2015)	HOG, LBP, SIFT, SURF, Propuesto (Prop.)	ANN	GTS	Exactitud: HOG+ANN 96,77% LBP+ANN 96,59% SIFT+ANN 97,74% SURF+ANN 97,46% Prop.+ANN 98,62%	HOG+ANN 50fps LBP+ANN 100fps SIFT+ANN 1fps SURF+ANN 2fps Prop.+ANN 200fps
Continúa					

(Guoqing Le, Xue Yuan, Jing Zhang, & HanSong Li, 2016)	-----	PCANet	GTS	Exactitud:	NE
			39.209		
			entrenamie	97,76%	
			nto y		
			12.630 test		
			43 clases		

Al comparar los métodos presentados en la **Tabla 5**, se analiza los resultados aplicados sobre una base de datos en común, con lo cual se determina que, el método que más se utiliza para extracción de características es HOG en (Wahyono & Jo, 2014), (Stallkamp, Schlipsing, Salmen, & Igel, 2012), (Zaklouta & Stanciulescu, 2014), (Greenhalgh & Mirmehdi, 2012), (Zaklouta & Stanciulescu, 2011), (Yin, Ouyang, Liu, & Wei, 2015), siendo uno de los favoritos por los buenos resultados en general que entrega. El algoritmo clasificador más utilizado es SVM en (Wahyono & Jo, 2014), (Zhu, Wang, Yao, & Bai, 2013), (Greenhalgh & Mirmehdi, 2012), (Fleyeh H. , 2015), (Aly, Deguchi, & Murase, 2013), debido a sus buenos resultados y amplio conocimiento del mismo. El método de reconocimiento con la mejor medida de rendimiento es el presentado en (Zhu, Wang, Yao, & Bai, 2013) que utiliza LCC+SPM como extractores de características en dos capas y SVM como algoritmo clasificador aplicado sobre la base de datos GTS, obteniendo resultados de 99,67%, obteniendo la mayor cantidad de errores generados por: la similitud entre señales de tránsito, la mala iluminación, desenfoque y señales de tránsito con suciedad o desgaste. El tiempo que demora LCC+SPM+SVM es de 32,5 milisegundos, en cual se encuentra dentro del umbral de tiempo real, ya que las aplicaciones en tiempo real emplean un máximo de 30fps (33 milisegundos), pero debido a la cercanía con el umbral y a que muchas veces el tiempo de ejecución del sistema puede variar en aplicaciones de campo, es recomendable optimizar el algoritmo para que funcione en un mejor tiempo para aplicaciones en tiempo real.

Un método que puede ser aplicado en tiempo real esta descrito en (Yin, Ouyang, Liu, & Wei, 2015) aplicado sobre la base de datos GTS, donde los mejores resultados obtenidos que pueden aplicarse en tiempo real son: HOG+ANN con 96,77% de exactitud y manejando 50fps y su algoritmo de reconocimiento propuesto Prop.+ANN

con un 98,62% y 200 fps. Por lo cual se puede concluir que HOG es uno de los descriptores más utilizados y con mejores resultados junto con algoritmos basados en ANN, de estos algoritmos ELM es óptimo para manejar multclasificación (Huang, Zhou, Ding, Ding, & Zhag, 2012) y puede trabajar en aplicaciones en tiempo real con excelentes resultados.

CAPÍTULO III

3. RECONOCIMIENTO DE SEÑALES DE TRÁNSITO REGULATORIAS DEL ECUADOR

3.1 Introducción

En el presente capítulo se realiza el análisis de imágenes de señales de tránsito, se realiza un preprocesamiento y se extraen características para realizar la etapa de reconocimiento de las mismas, con el fin de determinar si corresponden a la clasificación de: pare, ceda el paso, límite máximo de velocidad. Del resultado de esta clasificación se realizará otra etapa de reconocimiento para determinar el tipo de límite máximo de velocidad que se está analizando.

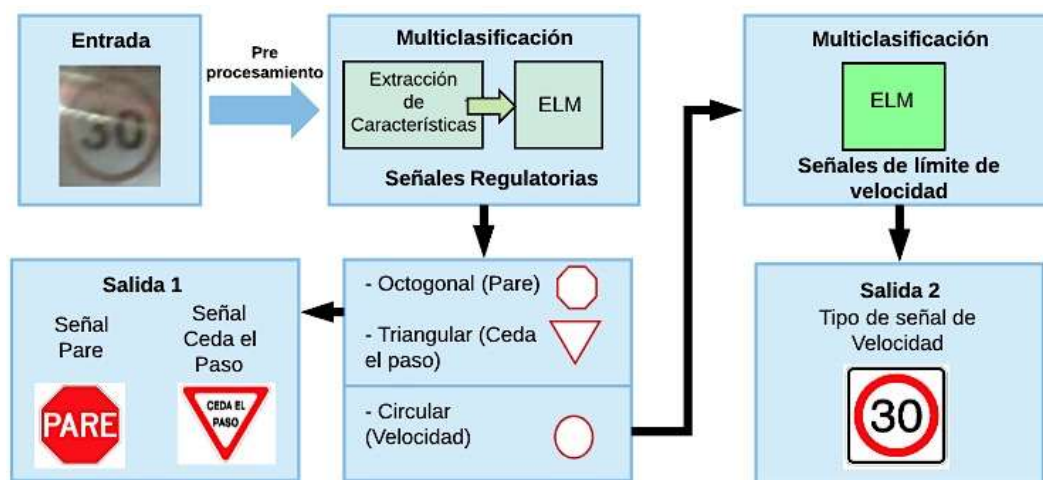


Figura 20. Esquema del algoritmo de reconocimiento de señales de tránsito de tipo regulatorias del Ecuador basado en HOG y ELM.

En la **Figura 20**, se encuentra las etapas del reconocimiento que se detallan a continuación:

- **Pre-procesamiento de las imágenes:** Es la primera etapa en la cual ingresa la imagen e inicialmente se transforma la imagen a escala de grises, luego se

redimensiona las imágenes a una escala estándar de 32 x 32 píxeles, determinado como el mejor tamaño para extraer características de señales de tránsito (Conlago, Yunda, & Flores, 2016). Para generar una mejor calidad de imagen y evitar la variación de iluminación se ecualiza la imagen en gris normalizando el brillo y aumentando el contraste de la imagen. La imagen resultante en escala de grises, redimensionada y ecualizada es la salida de esta etapa.

- **Extracción de características:** Es la segunda etapa, extrae las características de la imagen resultante de la primera etapa utilizando la técnica de HOG con valores predeterminados de: tamaño de celda 8x8, tamaño de bloque 2x2 y 9 orientaciones. Estos valores predeterminados de HOG se determinan en (Conlago, Yunda, & Flores, 2016).
- **Multiclasificación de señales regulatorias:** Es la tercera etapa, en esta etapa se utiliza el HOG resultante de la segunda etapa para entrenar una máquina de aprendizaje que nos determine la multiclasificación en tres clases: pare, ceda el paso y velocidad. Como resultado de esta etapa se obtendrá la salida 1, en la cual se muestra la clasificación entre i) pare, ii) ceda el paso y iii) señales de velocidad; estas últimas pasan a la siguiente etapa.
- **Multiclasificación de señales de límite de velocidad:** Es la etapa final, en esta etapa la entrada es la señal de velocidad y se obtendrá la salida 2, la cual muestra el tipo de velocidad máxima utilizando una máquina de aprendizaje. La multiclasificación es de 14 clases, que son las señales de velocidad utilizadas a nivel nacional en Ecuador, van desde 10km/h hasta 100km/h.

3.2 Pre-Procesamiento de las imágenes

En la primera parte ingresan ROIs (extraídas previamente de algún programa previo) enfocadas a señales de tránsito, las cuales necesitan del preprocesamiento para mejorar su información contenida en las mismas, debido a que se pueden encontrar en condiciones de iluminación muy variable y extrema. Las fases de la etapa de pre-procesamiento se muestran en la *Figura 21*.




Figura 21. Fases de la etapa de pre-procesamiento.

3.2.1 Escala de grises de la imagen

Inicialmente la imagen se pasa a escala de grises debido a que tiene menor dificultad analizar un solo canal de 8 bits y no es necesario analizar el color de la imagen debido a que las características que se extraen son basadas en forma. En la *Figura 22* se encuentra el histograma de una imagen de 20km/h en escala de grises, determinada de una imagen con poca iluminación. Se puede observar que la tendencia del histograma se encuentra hacia la izquierda, donde el nivel de gris es mayor.

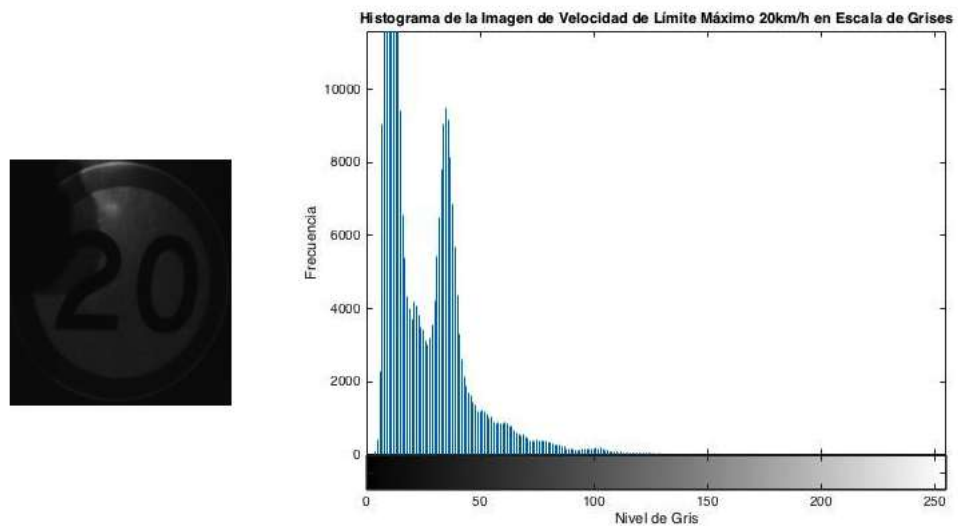


Figura 22. Histograma de imagen 20km/h en escala de grises en baja iluminación.

3.2.2 Redimensionamiento de la imagen 32x32 pixeles

Se redimensiona la imagen a 32x32 pixeles ya que es el mejor tamaño para extraer características de señales de tránsito (Conlago, Yunda, & Flores, 2016), es necesario estandarizar el tamaño de las señales para obtener el vector HOG de un mismo tamaño y poder realizar la comparaciones entre los resultados.

3.2.3 Ecualizador aplicado a la imagen

El ecualizador se utiliza para normalizar el brillo e incrementar el contraste de la imagen, de este modo mitigar la gran variación de iluminación que se presenta en las imágenes de las señales de tránsito y obtener mejores características que ayuden a determinar los tipos de señales. El ecualizador utilizado es utilizado de la librería de OpenCV (Berkeley Software Distribution, 2018). La función ecualiza el histograma de la imagen utilizando el siguiente algoritmo:

- Calcula el histograma H de la imagen.
- Normaliza el histograma de modo que, la suma de los intervalos de histograma sea 255.
- Calcula la integral del histograma como se muestra en (1).

$$H'_i = \sum_{0 \leq j \leq i} H(j) \quad (1)$$

- Transforma la imagen utilizando H' con (2).

$$I_e(x, y) = H'(I(x, y)) \quad (2)$$

donde:

I es la imagen en escala de gris, I_e es la imagen ecualizada.

En la **Figura 23** el histograma pertenece a la imagen de 20km/h redimensionada a 32x32 pixeles y ecualizada, por lo que nos muestra una distribución más uniforme a lo largo del nivel de gris. Y visualmente se obtiene mayor información de la imagen ya que se puede distinguir de mejor manera el símbolo que representa respecto a la **Figura 22**.

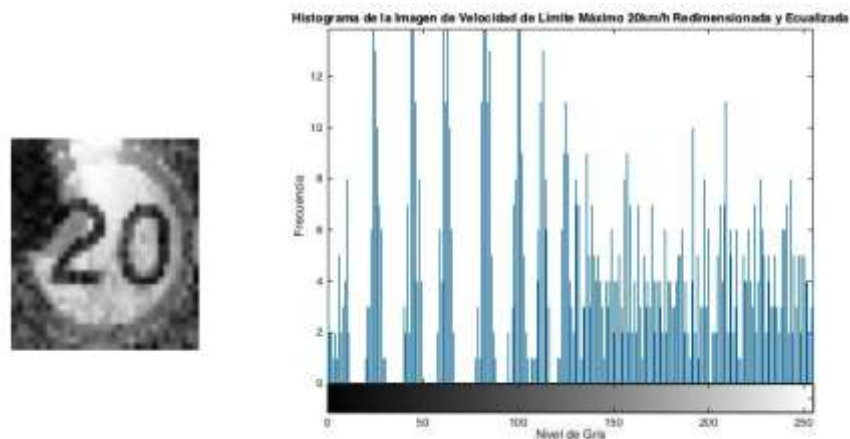


Figura 23. Histograma de imagen 20km/h en escala de grises, redimensionada 32x32 y ecualizada.

3.3 Extracción de características usando HOG

Los descriptores HOG fueron originalmente propuestos por (Dalai & Triggs, 2005), para calcular los descriptores HOG de cualquier imagen como una señal de tránsito, inicialmente esta imagen se divide en varias celdas y varias ubicaciones de orientación, como se muestra en la **Figura 24**. Para cada celda, se recoge un histograma unidimensional local con: las direcciones del gradiente de las orientaciones de los bordes sobre los píxeles de la celda.




Figura 24. Cálculo del descriptor HOG de una señal de tránsito.

Fuente: (Fleyeh H. , 2015)

Para una mejor invariancia a los cambios de iluminación, como las sombras, el histograma local se acumula en un área más grande llamada bloques. Para mejorar la

contribución de las celdas en el descriptor de imagen final, se invoca la superposición entre estas celdas. Las orientaciones de los bordes se dividen en varias ubicaciones. Estos compartimientos están equiespaciados en el intervalo 0 - 180° para gradiente sin signo y -90° a 90° para gradientes con signo. Las orientaciones de los bordes deben caber en uno de estos contenedores. Los histogramas recolectados para las diferentes celdas en los contenedores en el mismo bloque se concatenan para hacer el conjunto final de características del objeto bajo consideración. El resultado del descriptor HOG es una cantidad discreta de características que describe la imagen de entrada. La cantidad de funciones depende de la cantidad de celdas y contenedores de orientación.

3.3.1 Cálculo del gradiente

El gradiente se define como “el cambio direccional en la intensidad de la imagen” (Universidad Autónoma de Barcelona, 2018), se calcula para cada uno de los píxeles de la imagen y queda definido para cada pixel por dos valores:

- Dirección donde el cambio de intensidad es máximo.
- Magnitud del cambio en la dirección de máxima variación.




Figura 25. Intensidad de cada pixel de imagen en escala de grises.

En el caso de investigación la intensidad se analiza para una imagen en escala de grises como se muestra en la **Figura 25**, el cálculo del gradiente se realiza basándose en la diferencia de intensidad de los píxeles adyacentes en dirección horizontal (3) y vertical (4) (Universidad Autónoma de Barcelona, 2018).

$$dx = I(x + 1, y) - I(x - 1, y) \quad (3)$$

$$dy = I(x, y + 1) - I(x, y - 1) \quad (4)$$

Se obtiene la magnitud (6) y dirección (5) del gradiente.

$$\theta(x, y) = \tan^{-1} \frac{dy}{dx} \quad (5)$$

$$g(x, y) = \sqrt{dx^2 + dy^2} \quad (6)$$

3.3.2 Cálculo de los histogramas de orientación

El procedimiento para el cálculo de los histogramas mostrado en **Figura 26**, inicialmente divide la imagen en un número fijo de celdas (C), de cada una de estas celdas se obtiene un histograma de las orientaciones de los gradientes de esa celda, para esto inicialmente debemos fijar el tamaño de la celda (cuantos píxeles por celda), luego para el rango de orientaciones que va de $0-180^\circ$ sin signo y de -90° a 90° con signo, debemos dividirlo en un número de intervalos fijo (k) para asignar los gradientes dentro de cada intervalo del rango de orientaciones. El histograma final se obtiene acumulando la magnitud de todos los gradientes asignados al intervalo. Este procedimiento se realiza para cada una de las celdas obteniendo un resultado como se muestra en la **Figura 27**.




Figura 26. Procedimiento para el cálculo de los histogramas.

Fuente: (Universidad Autónoma de Barcelona, 2018)

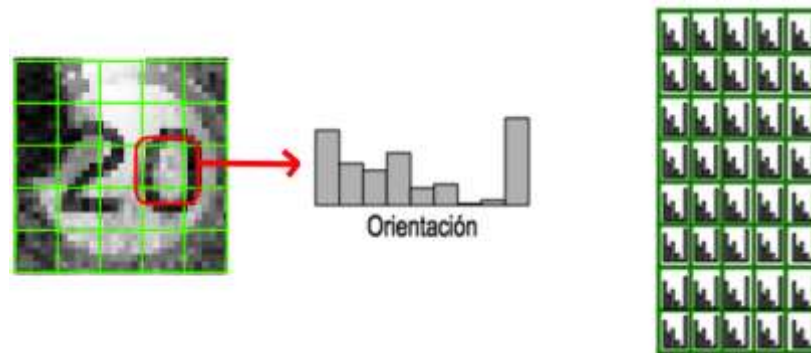


Figura 27. Resultado del cálculo de histogramas de orientación.

Fuente: (Universidad Autónoma de Barcelona, 2018)

La fórmula para el cálculo del histograma (7) se obtiene de la acumulación de todos los gradientes de la celda $g(x, y)$ ponderados por un factor $\omega_k(x, y)$ que nos determina la asociación del gradiente al intervalo k (8) como se muestra en la **Figura 28**.

$$h(k) = \sum_{(x,y) \in C} \omega_k(x, y) g(x, y) \quad (7)$$

$$\omega_k(x, y) = \begin{cases} 1 & \text{si } (k-1)\delta\theta \leq \theta(x, y) \leq k\delta\theta \\ 0 & \text{en caso contrario} \end{cases} \quad (8)$$

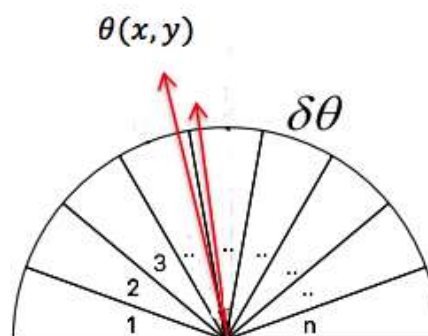


Figura 28. Gradiente asociado al intervalo del rango de orientaciones.

3.3.3 Cálculo del descriptor

La representación final del descriptor HOG se obtiene a partir de los histogramas de orientación calculados en cada una de las celdas que dividen la imagen, se los normaliza y agrupa en forma de bloques para obtener su representación final (Universidad Autónoma de Barcelona, 2018). La intensidad de iluminación produce cambios importantes en los valores del histograma debido a la variación de los contrastes, para disminuir estas variaciones locales en el histograma debido al contraste se lo normaliza. La normalización se realiza respecto a bloques, que son una agrupación de varias celdas vecinas. Para cada bloque se concatena los histogramas de cada celda como se muestra en *Figura 29*, en un vector que es la representación del mismo (9).

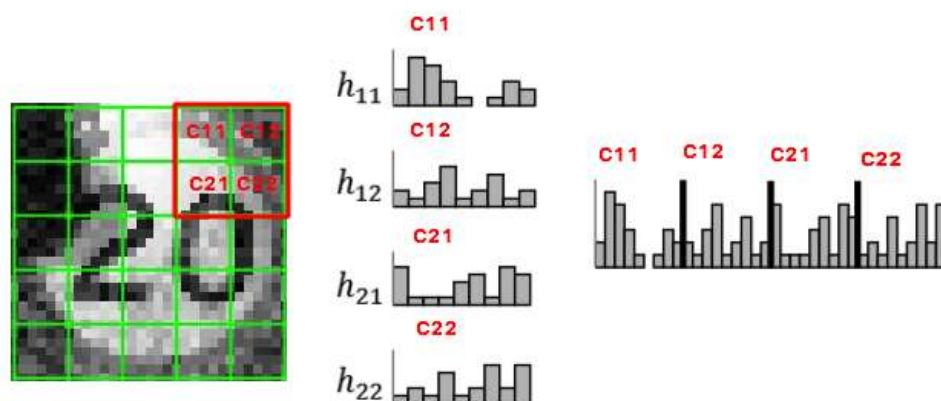


Figura 29. División en bloques y concatenación.

Fuente: (Universidad Autónoma de Barcelona, 2018)

La normalización se obtiene dividiendo cada uno de los componentes del vector por su norma L2 obteniendo el vector normalizado (10). Al normalizar se suma un ε que es una constante de valor muy pequeño que nos ayuda a no tener divisiones para cero en caso de tener un componente del vector en cero.

$$v = (x_1, \dots, x_n) \quad (9)$$

$$v' = \frac{v}{\sqrt{\|v\|^2 + \varepsilon}} \quad (10)$$

Los bloques se definen de tal modo que tengan un cierto solapamiento entre ellos, la redundancia que se obtiene va a ayudar a que el descriptor sea más robusto ante deformaciones y variaciones en la forma del objeto. Generalmente el solapamiento es de una celda entre bloques tanto en horizontal como en vertical. El descriptor HOG se obtiene concatenando la representación normalizada de todos los bloques solapados.

Finalmente se detalla los parámetros necesarios para el descriptor HOG, los mejores parámetros de HOG para la clasificación de señales de tránsito esta detallado en (Conlago, Yunda, & Flores, 2016):

- Tamaño de celda: 4x4 píxeles.
- Signo del gradiente: con signo de -90 a 90 grados.
- Número de intervalos del histograma de orientaciones: $k = 9$.
- Número de celdas en cada bloque: 2x2 celdas.

Con esta información podemos calcular cuántos componentes tiene el vector HOG con (11). Este número depende del número de bloques que se pueda colocar en la imagen, se puede calcular con (12).

$$n = \#bloques \times \frac{\#celdas}{bloque} \times \#intervalos_histograma \quad (11)$$

$$\#bloques = \#celdas - \frac{\#celdas}{bloque} + 1 \quad (12)$$

Para estos parámetros obtenemos que el número de componentes de HOG con mejores resultados presentados en (Conlago, Yunda, & Flores, 2016) es de: 324 componentes.

3.4 Multiclasificación de señales de tránsito

El reconocimiento de señales de tránsito es un problema de multiclasificación (Stallkamp, Schlipsing, Salmen, & Igel, 2012) (Greenhalgh & Mirmehdi, 2012), debido a que la clasificación se realiza en múltiples clases, es necesario utilizar un algoritmo que soporte este tipo de características, por lo que se utiliza ELM (Huang, Yu, Gu, & Liu, 2017) como clasificador por etapas. La primera etapa tiene como salida la clasificación de la señal en las clases Pare, Ceda el Paso y Límite de Velocidad. La segunda etapa se alimenta de la primera con el resultado de clasificación de límite de velocidad, para poder clasificar las señales de límite de velocidad en señales de: 10km/h, 15km/h, 20km/h, 25km/h, 30km/h, 35km/h, 40km/h, 45km/h, 50km/h, 60km/h, 70km/h, 80km/h, 90km/h y 100km/h. Como resultado se obtiene un clasificador de 14 clases, dando como resultado el tipo de señal de límite de velocidad. Ver **Figura 30**.

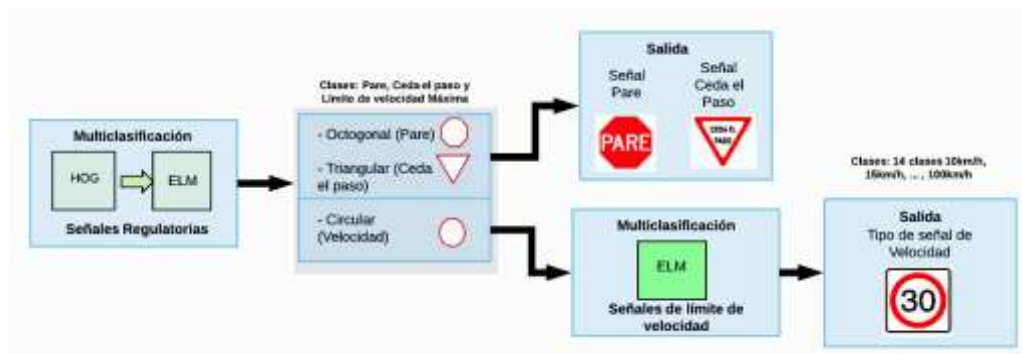


Figura 30. Esquema de algoritmo para multiclasificación de señales de tránsito.

3.4.1 ELM

ELM es un método de aprendizaje para redes neuronales “feedforward” de una sola capa oculta (SFLN) propuesto en (Huang, Zhu, & Siew, 2006), donde se elige aleatoriamente el peso de los nodos ocultos y determina analíticamente el peso de salida de la SFLN. En general el algoritmo proporciona un buen rendimiento con una velocidad de aprendizaje extremadamente rápida. Se centra en resolver aplicaciones complejas y que manejan una gran cantidad de datos, siendo su aprendizaje miles de

veces más rápido que los algoritmos de aprendizaje convencionales para redes neuronales “feedforward” (Huang G.-B. , 2015).




Figura 31. Estructura del modelo de una SLFN.

Fuente: (Huang G.-B. , 2013)

Para analizar ELM inicialmente se debe revisar el modelo de una SFLN, para N muestras arbitrarias distintas (x_i, t_i) , donde $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ y $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m$, una SFLN estandar con \tilde{N} nodos ocultos y función de activación $g(x)$ se modela matemáticamente como:

$$\sum_{i=1}^{\tilde{N}} \beta_i g(x_j) = \sum_{i=1}^{\tilde{N}} \beta_i g(w_i \cdot x_i + b_i) = t_j \quad (13)$$

$$j = 1, \dots, N$$

Donde $w_i = [w_{i1}, w_{i2}, \dots, w_{im}]^T$ son los pesos que conectan el i -ésimo nodo oculto y los nodos de entrada, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ son los pesos que conectan el i -ésimo nodo oculto y los nodos de salida, \tilde{N} es el número de nodos en la capa oculta, b_i es el bias del i -ésimo nodo oculto. $w_i \cdot x_i$ denota el producto punto entre w_i y x_i . Las N ecuaciones anteriores pueden escribirse de forma compacta como:

$$H\beta = T \quad (14)$$

Donde:

$$H(w_1, \dots, w_{\tilde{N}}, b_1, \dots, b_{\tilde{N}}, x_1, \dots, x_N) = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_{\tilde{N}} \cdot x_1 + b_{\tilde{N}}) \\ \dots & \dots & \dots \\ g(w_1 \cdot x_N + b_1) & \dots & g(w_{\tilde{N}} \cdot x_N + b_{\tilde{N}}) \end{bmatrix}_{N \times \tilde{N}}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \dots \\ \beta_{\tilde{N}}^T \end{bmatrix}_{\tilde{N} \times m} \quad \text{y} \quad T = \begin{bmatrix} t_1^T \\ \dots \\ t_{\tilde{N}}^T \end{bmatrix}_{\tilde{N} \times m}$$

En (14) necesitamos calcular β que son los pesos de las neuronas de salidas del sistema ya que x_i es la entrada, w_i y b_i son pesos y bias randómicos y T es la salida para clasificación del sistema. Para encontrar β se puede aplicar la solución de mínimos cuadrados detallada en (Huang, Zhu, & Siew, 2006), donde se obtiene la fórmula (15).

$$\beta = H^\dagger T \quad (15)$$

H^\dagger es la inversa generalizada Moore-Penrose de la matriz H , citada en (Huang, Zhu, & Siew, 2006). Con esto podemos calcular directamente los pesos de salida y obtener el entrenamiento de la SLFN, este es el método conocido como ELM. Como función de activación para la red neuronal existen varios algoritmos detallados en (Huang G.-B., 2015), de estos se escogió la función de activación sigmoide (16) ya que esta función es óptima para una gran cantidad de datos dispersos (Mahadevan, 2017), lo que representa la problemática a resolver con el algoritmo.

$$g(w_i \cdot x_i + b_i) = \frac{1}{1 + e^{-(w_i \cdot x_i + b_i)}} \quad (16)$$

3.4.2 Kd-tree

Un árbol Kd es un árbol de búsqueda binaria que organiza K-dimensional puntos de datos. Los árboles kd son una estructura de datos útil para varias aplicaciones, como búsquedas que involucran una clave de búsqueda multidimensional (por ejemplo búsquedas de rango y búsqueda de vecinos más cercanos), donde cada nodo de este árbol es un punto k-dimensional (Kuo & Lin, 2007).

Cada nodo genera implícitamente un hiperplano de división que divide el espacio en dos partes, conocidas como espacios medios. Los puntos a la izquierda de este hiperplano están representados por el subárbol izquierdo de ese nodo y los puntos a la derecha del hiperplano están representados por el subárbol derecho. La dirección del hiperplano se elige de la siguiente manera: cada nodo en el árbol está asociado con una de las dimensiones k , con el hiperplano perpendicular al eje de esa dimensión (Bentley, 1975). Para realizar una consulta en el árbol k -d como en **Figura 32**, se establece el número de datos examinados en la búsqueda, lo que genera una región en la cual se realiza la búsqueda del vecino más cercano utilizando k NN (Zaklouta & Stanciuslescu, 2014).




Figura 32. Consulta en un árbol Kd.

Fuente: (de Berg, Cheong, van Kreveld, & Overmars, 2008)

Para construir el árbol k -dimensional se utilizó el método canónico determinado en (de Berg, Cheong, van Kreveld, & Overmars, 2008) con los siguientes detalles:

- A medida que se recorre el árbol, se recorre los ejes seleccionados para seleccionar los planos de división (Por ejemplo, en un árbol tridimensional, la raíz tendría un plano alineado x , los hijos de la raíz ambos tendrían planos alineados en y , los nietos de la raíz todos tendrían planos alineados en z , los bisnietos de la raíz serían todos tienen planos alineados x , todos los tataranietos de la raíz tienen planos alineados en y , etc.).

- Los puntos se insertan seleccionando la mediana de los puntos que se colocan en el subárbol. Lo que ayuda a que el árbol este equilibrado.

3.4.3 SVM

SVM es una de las máquinas de aprendizaje más utilizadas, debido a la gran cantidad de información que existe y a la gran variedad de librerías que se han desarrollado sobre este algoritmo. El algoritmo utilizado se encuentra detallado en (Chang & Lin, 2011), donde se utiliza SVC (máquina de vectores de soporte para clasificación) enfocado a dos clases o multiclases. Para el entrenamiento del algoritmo resuelve el problema de optimización planteado en (17).

$$\min_{\varpi, b, \xi} \frac{1}{2} \varpi^T \varpi + C \sum_{i=1}^l \xi_i \quad (17)$$

$$\text{sujeto a: } y_i(\varpi^T \phi(x_i) + b) \geq 1 - \xi_i$$

$$\xi_i \geq 0, i = 1, \dots, l$$

Donde x_i es el vector de entrenamiento HOG, y_i es el vector con las etiquetas para la clasificación, $\phi(x_i)$ asigna a x_i a un espacio de mayor dimensionalidad y C es un parámetro de regularización (C inversamente proporcional al error). El parámetro ϖ es una variable de alta dimensionalidad con b como parámetro, ξ_i es un factor de holgura para evitar el sobreajuste y l es el número de datos de entrenamiento. Para realizar la clasificación se utiliza (18) donde el kernel que se utilizó para el entrenamiento es RBF (función de base radial) mostrada en (19) y los parámetros y_i, α_i están determinados en (Chang & Lin, 2011).

$$\text{sgn}(\varpi^T \phi(x_i) + b) = \text{sgn} \left(\sum_{i=1}^l y_i \alpha_i K(x_i, x) + b \right) \quad (18)$$

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (19)$$

3.4.4 Multiclasificación de señales regulatorias

Para la multiclasificación de señales regulatorias inicialmente se realiza el entrenamiento de ELM (Huang , Yu, Gu, & Liu, 2017) con una base de datos de descriptores HOG, con dimensión $X \in R^{324}$, de señales del Ecuador detallado en la **Tabla 6**. Para realizar las pruebas del algoritmo se sigue el diagrama de flujo detallado en **Figura 33**. Como resultado de ELM se va a obtener un vector de dimensiones 3x1, cada uno de los componentes del vector representan a cada una de las señales regulatorias clasificadas: pare, ceda el paso, límite máximo de velocidad. Ya que el resultado del clasificador ELM entrega valores analógicos (máximo es 1 y como mínimo 0) es necesario colocar un valor umbral el cual se determinó que sea 0,4 de la experimentación con la base de datos, todos los valores sobre este valor umbral equivalen a 1 y todos los valores menores o iguales al umbral equivalen a 0. En caso de tener varios componentes del vector en 1 la salida no reconocerá el tipo de señal.

3.4.5 Multiclasificación de señales de límite de velocidad

Para la multiclasificación de señales de límite de velocidad se utiliza ELM sobre una base de datos de señales de límite de velocidad generada con el descriptor HOG. La cantidad de imágenes de entrenamiento se muestra en **Tabla 6**, las cuales se encuentran en condiciones de iluminación normales y extremas en el espectro visible. Para realizar las pruebas se sigue el diagrama de flujo detallado en **Figura 34**. Como resultado de la multiclasificación de señales de límite velocidad se va a obtener un vector de dimensiones 14x1, cada uno de los componentes del vector representan a cada una de las señales de límite máximo clasificadas: 10 km/h, 15km/h, ..., 100km/h. El resultado del clasificador ELM entrega valores analógicos (máximo es 1 y como mínimo 0) por lo que es necesario colocar un valor umbral el cual se determinó que sea 0,4 de la experimentación con la base de datos, todos los valores sobre este valor umbral equivalen a 1 y todos los valores menores o iguales al umbral equivalen a 0. En caso de tener varios componentes del vector en 1 la salida no reconocerá el tipo de señal.




Figura 33. Diagrama de flujo multclasificación de señales regulatorias.




Figura 34. Diagrama de flujo multclasificación de señales de límite de velocidad máxima.

CAPÍTULO IV

4. PRUEBAS Y RESULTADOS

4.1 Introducción

En este capítulo se ejecutan las pruebas del algoritmo mostrado en la **Figura 20**, sobre la base de datos de prueba, conformada por señales regulatorias del Ecuador, tomadas en distintas condiciones de iluminación, algunas de estas imágenes en condiciones de iluminación extrema (gran cantidad de luz o poca cantidad de luz) en el espectro visible, con estas pruebas se obtiene los resultados finales del algoritmo de reconocimiento de señales de tránsito de tipo regulatorias del Ecuador basado en HOG (Zaklouta & Stanciulescu, 2011) y ELM (Huang G.-B. , 2013), y para compararlos se utilizan algoritmos SVM (Zabihi, Zabihi, Beauchemin, & Bauer, 2017) y Kd-tree (Zaklouta & Stanciulescu, 2011). El desempeño se basa en los resultados como clasificadores y si pueden ser utilizados en aplicaciones en tiempo real.

4.2 Tecnología utilizada para la implementación del algoritmo

El entrenamiento y las pruebas se realizaron con los siguientes parámetros en hardware y software:

- PC de escritorio con procesador Intel Core i5-3450 a 3,1GHz, 4 núcleos y 10Gb RAM.
- Sistema operativo Ubuntu 14.04 LTS de 64 bits.
- Lenguaje de programación C++.

4.3 Base de datos de entrenamiento y validación

La base de datos de señales del Ecuador esta generada por vectores HOG $X \in R^{324}$, la cantidad de imágenes para el entrenamiento se detallada en **Tabla 6**, a las cuales se

les colocó etiquetas para ingresar al entrenamiento y realizar las pruebas: 1000 imágenes para Pare=1, 743 para Ceda el Paso=2 y 15.694 para Límite de Velocidad Máxima=3 en total (estas imágenes tienen diferentes tipos de iluminación ya que son tomadas en condiciones normales de iluminación en el día, en días nublados, en la noche y en el amanecer donde las condiciones de iluminación son extremas). Del mismo modo se colocó etiquetas para las señales de velocidad de 10km/h=10, 20km/h=20, ..., 100km/h=100 sobre la base de entrenamiento.

Tabla 6.

Base de datos de entrenamiento señales regulatorias.

	Pare	Ceda el Paso	Límite de Velocidad Máxima	Muestra Negativa	Total
Número de imágenes	700	500	10.725	20.000	31.925

Las pruebas de funcionamiento se realizaron sobre la base de datos de señales regulatorias del Ecuador detallado en **Tabla 7** para la primera etapa de multclasificación de señales de tránsito regulatorias y para señales de tránsito de límite de velocidad máxima.

Tabla 7.

Base de datos de pruebas señales regulatorias.

	Pare	Ceda el Paso	Límite de Velocidad Máxima	Muestra Negativa	Total
Número de imágenes	300	243	4.969	10.000	15.512

4.4 Entrenamiento del algoritmo

Para realizar el entrenamiento de ELM es importante determinar el número de neuronas de la capa oculta necesarias para resolver el problema de clasificación, de tal manera que no se tenga un sobreajuste al colocar una gran cantidad de neuronas y las

respuestas de ELM no sean “memorizadas” o caso contrario sean muy pocas las neuronas que se utilicen de tal manera que no resuelvan el problema, (Huang G.-B. , 2015), para determinar la cantidad de neuronas a implementarse se realizó los entrenamientos variando la cantidad de neuronas de la capa oculta, en **Tabla 8** se muestra como fue mejorando el desempeño de ELM respecto al número de neuronas con las que se entrenó y en **Figura 35** se muestra cómo va incrementándose el tiempo que se demora el entrenamiento cuando incrementamos la cantidad de neuronas de la capa oculta.

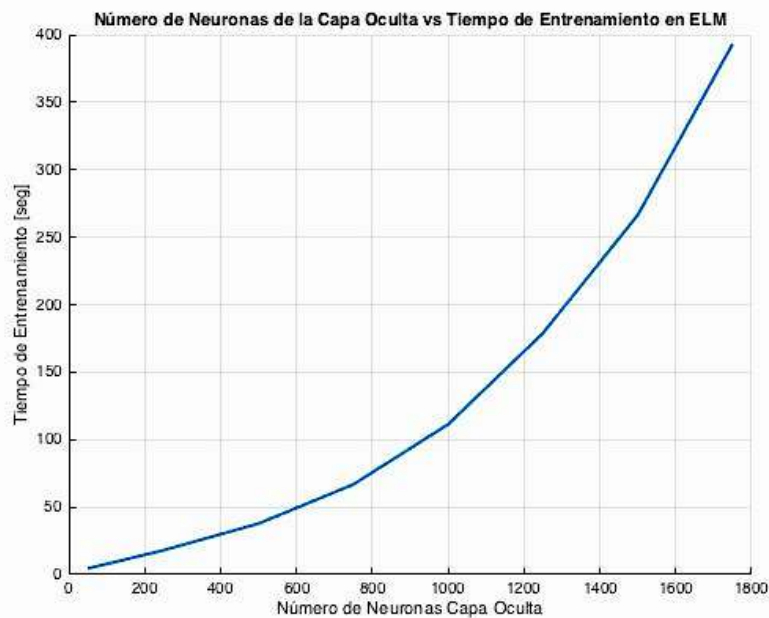


Figura 35. Número de neuronas en la capa oculta vs tiempo de entrenamiento ELM.

Tabla 8.

AUC según el número de neuronas en la capa oculta ELM.

# de neuronas en la capa oculta	50	100	250	500	1000	1500	2000
AUC	0,9227	0,9928	0,97868	0,99769	0,99075	0,99174	0,99832

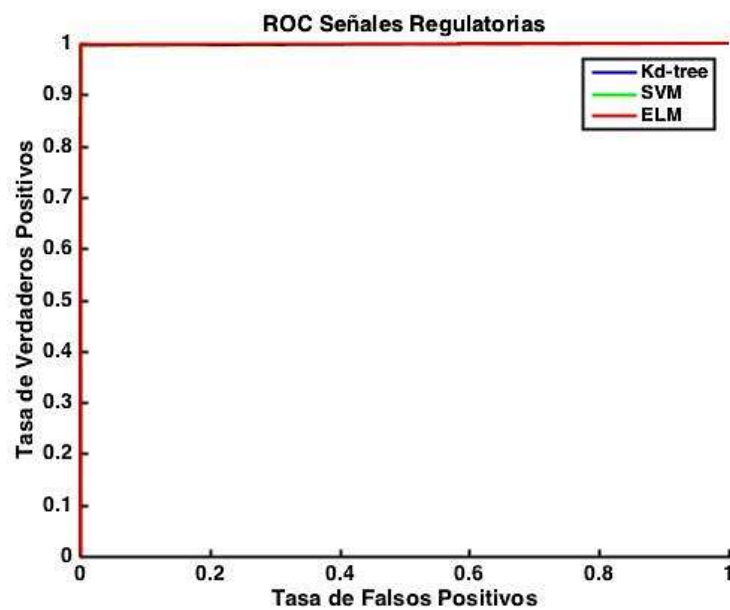
4.5 Pruebas de funcionamiento

Tabla 9.

AUC de la clasificación para señales regulatorias y de límite de velocidad con Kd-tree, SVM y ELM.

Clasificadores	Kd-tree	SVM	ELM
AUC	0,9973	0,9983	0,9983
Señales Regulatorias			
AUC	0,9387	0,9697	0,9554
Señales de Límite de Velocidad			


Las pruebas de funcionamiento se presentan en la **Tabla 9**, para señales regulatorias. Además se compara esta propuesta con los algoritmos para clasificación SVM y Kd tree mediante las curvas ROC, ver en la **Figura 36**, y el parámetro AUC.



(a)

Continúa





(b)

Figura 36. Curvas ROC para algoritmos de clasificación: (a) señales regulatorias (pare, ceda el paso y velocidad) con Kd-tree, SVM y ELM (b) señales de límite de velocidad con Kd-tree, SVM y ELM.

De los resultados presentados por los algoritmos de reconocimiento se pueden obtener parámetros de evaluación como son: sensibilidad (20), la razón de falsos positivos (21), exactitud (22) y la razón de verdaderos negativos (23) para determinar los mejores resultados. De estos parámetros los de mayor relevancia son la exactitud y sensibilidad. Para la primera etapa de multclasificación se presentan los resultados en **Tabla 10** y para la segunda etapa de multclasificación se presentan los resultados en **Tabla 11**.

$$VPR = \frac{VP}{(VP + FN)} \quad (20)$$

$$FPR = \frac{FP}{(FP + VN)} \quad (21)$$

$$ACC = \frac{(VP + VN)}{(VP + FN + FP + VN)} \quad (22)$$

$$SPC = \frac{VN}{(FP + VN)} = 1 - FPR \quad (23)$$

Donde los parámetros VP (verdaderos positivos), FP (falsos positivos), VN (verdaderos negativos), FN (falsos negativos) se extraen de la comparación de los resultados del clasificador con las etiquetas colocadas en la base de datos para determinar cada clase. Con estos parámetros se puede calcular VPR (sensibilidad o razón de verdaderos positivos), FPR (razón de falsos positivos), ACC (exactitud) y SPC (especificidad o razón de verdaderos negativos) (Concejero, 2004).

Tabla 10.

Resultados del algoritmo de reconocimiento de señales regulatorias.

Resultados del algoritmo señales regulatorias	Sensibilidad	Razón de falsos positivos	Exactitud	Razón de verdaderos negativos
ELM	0,9978	0,0012	0,9985	0,9988

Tabla 11.

Resultados del algoritmo de reconocimiento de señales de límite de velocidad.

Resultados del algoritmo señales límite de velocidad	Sensibilidad	Razón de falsos positivos	Exactitud	Razón de verdaderos negativos
ELM	0,9416	0,0309	0,9671	0,9691

4.6 Tiempo de cómputo

El tiempo de cómputo se realizó sobre las etapas detalladas en la **Figura 20**, probadas sobre el hardware y software anteriormente detallados, los tiempos totales de procesamiento con el clasificador basado en ELM es de 8,2087 ms, con el clasificador basado en SVM es de 155,61 ms y con el clasificador basado en Kd-tree es de 33,2496 ms.

4.7 Conclusiones del capítulo

Como conclusión el algoritmo con mejores características para utilizarse en ADAS en aplicaciones en tiempo real para el reconocimiento de señales de tránsito de prohibitivas es el algoritmo basado en ELM, el cual tiene un excelente desempeño en multclasificación con tiempos de hasta 6,8223 ms, lo cual también lo hace una buena opción para complementar otros sistemas ADAS más complejos.

CAPÍTULO V

5. CONCLUSIONES Y TRABAJOS FUTUROS

5.1 Conclusiones

En la presente tesis se realizó un algoritmo para el reconocimiento de señales de tránsito regulatorias en condiciones extremas de iluminación en el espectro visible. Este algoritmo de reconocimiento se aplicó sobre una base de datos de imágenes recolectadas en varios lugares del Ecuador, con algunos factores que pueden afectar la detección como: desvanecimiento de color, desorientación de las señales, desenfoque de movimiento, condiciones extremas de iluminación en el espectro visible y varias otras.

En la etapa de multclasificación se realizó el entrenamiento y pruebas de validación con algoritmos basados en Kd-tree, SVM y ELM, de los cuales se concluyó que el algoritmo que presenta las mejores características para la aplicación de reconocimiento en tiempo real es ELM generando buenos resultados tanto en la multclasificación de la primera etapa $AUC=0,9983$, exactitud de 0,9985 y sensibilidad de 0,9978 como en la segunda etapa $AUC=0,9554$, exactitud 0,9978 y sensibilidad 0,9416 y con un gran desempeño en el tiempo de procesamiento: primera etapa 1,0574 ms, segunda etapa 6,8223 ms, demostrando que este algoritmo fácilmente se puede adaptar a ADAS más complejos.

Al realizar pruebas sobre la base de datos con iluminación variable y en muchos casos extrema se obtuvo que el algoritmo de reconocimiento se muestra casi invariante en su desempeño con iluminación variable, el más grande problema que se puede observar en la clasificación es el ruido que presentan las imágenes por el desenfoque de movimiento el cual puede ser solucionado aplicando filtros que mejoren esta condición.

Finalmente, respecto a tiempo de procesamiento el algoritmo propuesto toma 6,82 ms, superando a todos los algoritmos del estado del arte.

5.2 Trabajos futuros

Incluir todas las señales de tránsito de reglamentación y prevención en la etapa de reconocimiento, generando un algoritmo basado en ELM para el reconocimiento de las señales de tránsito más utilizadas.

Ampliar la base de datos, aumentando un mayor número de imágenes en señales de velocidad para mejorar los índices de clasificación.

REFERENCIAS BIBLIOGRÁFICAS

- Agencia Nacional de Tránsito. (2017). *ant*. Recuperado el 21 de Noviembre de 2017, de Agencia Nacional de Tránsito
- Aly, S., Deguchi, D., & Murase, H. (2013). Blur-invariant Traffic Sign Recognition Using Compact Local Phase Quantization. *IEEE International 16th Annual Conference on Intelligent Transportation Systems (ITSC)*, 821-827.
- Bentley, J. L. (1975). Multidimensional binary search trees used for associative searching. *Communications of the ACM*, 509 - 517.
- Berkeley Software Distribution. (2018). *OpenCV*. Recuperado el 09 de 01 de 2018, de <https://docs.opencv.org/2.4/modules/imgproc/doc/histograms.html>
- BMW Group. (2016). *BEYOND ADAS – HIGHLY AND FULLY AUTOMATED DRIVING*. Londres. Recuperado el 10 de 02 de 2017, de <https://www.bmwusa.com/vehicles/7-series.html>
- Boudette, N. (19 de Enero de 2017). Tesla's Self-Driving System Cleared in Deadly Crash. *The New York Times*.
- Chang, C.-C., & Lin, C.-J. (2011). LIBSVM: A Library for Support Vector Machines. *ACM Transactions on Intelligent Systems and Technology*, 2, 1 - 27.
- Chiang, H.-H., Chen, Y.-L., & Wang, W.-Q. (2010). Road speed sign recognition using edge-voting principle and learning vector quantization network. *Computer Symposium (ICS), 2010 International*.
- CINTEL. (2010). *Sistemas Inteligentes de Transporte - ITS en Colombia* (Vol. 03). Interactic.
- Ciresan, D., Meier, U., Masci, J., & Schmidhuber, J. (2011). A committee of neural networks for traffic sign classification. *IEEE International Joint Conference on Neural Networks*, 1918 - 1921.
- Concejero, P. (2004). *Comparación de modelos de curvas ROC para la evaluación de procedimientos estadísticos de predicción en investigación de mercados*. Tesis Doctoral, Universidad Complutense de Madrid, Madrid.
- Conlago, C., Yunda, J., & Flores, M. J. (2016). *Sistema automático de detección y reconocimiento de señales de tránsito en intersecciones viales para aplicaciones en vehículos inteligentes*. Quito: Universidad de las Fuerzas Armadas ESPE.
- Continental. (2018). *Continental Automotive World*. Recuperado el 10 de 02 de 2018, de <https://www.continental-automotive.com/en-gl/Passenger-Cars/Chassis-Safety/Advanced-Driver-Assistance-Systems>

- Cruzado Hernando, D. (2015). *Detección y reconocimiento de señales de tráfico*. Madrid, España: Universidad Carlos III de Madrid.
- Dalai, N., & Triggs, B. (2005). Histograms of Oriented Gradients for Human Detection. *IEEE Computer Vision and Pattern Recognition*.
- de Berg, M., Cheong, O., van Kreveld, M., & Overmars, M. (2008). Computational Geometry || Orthogonal Range Searching. 95 - 120.
- Eichner, M. L., & Breckon, T. P. (2008). Integrated speed limit detection and recognition from real-time video. *Intelligent Vehicles Symposium, 2008 IEEE*.
- Fleyeh, H. (2015). Traffic Sign Recognition without Color Information. *IEEE Colours and Visual Computing Symposium (CVCS)*.
- Fleyeh, H., & Dougherty, M. (2008). Traffic sign classification using invariant features and Support Vector Machines. *IEEE Intelligent Vehicles Symposium, 530 - 535*.
- Gao, H., Liu, C., Yu, Y., & Li, B. (2014). Traffic Signs Recognition Based on PCA-SIFT. *Intelligent Control and Automation (WCICA), 5070 - 5076*.
- Getting the data quality from IoT. (2017). *Spotless Data*. Obtenido de <https://spotlessdata.com/blog/getting-data-quality-iot>
- Gomez, J., & Bromberg, S. (2014). Design and evaluation of a traffic sign recognition system based on support vector machines. *IEEE Imagen, Signal Processing and Artificial Vision (STSIVA)*.
- Greenhalgh, J., & Mirmehdi, M. (2012). Real-Time Detection and Recognition of Road Traffic Signs. *IEEE Transactions on Intelligent Transportation Systems, 13(4), 1498-1506*.
- Gu, Y., Yendo, T., Tehrani, M. P., Fujii, T., & Tanimoto, M. (2010). A new vision system for traffic sign recognition. *IEEE Intelligent Vehicles Symposium, 7 - 12*.
- Gudigar, A., Chokkadi, S., & U, R. (2014). A review on automatic detection and recognition of traffic sign. *Science+Business Media Multimed Tools Appl*.
- Gudigar, A., Jagadale, B. N., P.K., M., & U., R. (2012). Kernel Based Automatic Traffic Sign Detection and Recognition Using SVM. *Eco-friendly Computing and Communication Systems, 305, 153 -161*.
- Guoqing Le, Xue Yuan, Jing Zhang, & HanSong Li. (2016). Traffic sign recognition based on PCANet. *IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC), 807 - 811*.
- Hoang, A.-T., Koide, T., & Yamamoto, M. (2015). Real-time Speed Limit Traffic Sign Detection System Robust Automotive Environments. *IEIE Transactions on Smart Processing and Computing, 237-250*.

- Huang, Z., Yu, Y., Gu, J., & Liu, H. (2017). An Efficient Method for Traffic Sign Recognition Based on Extreme Learning Machine. *IEEE Transactions On Cybernetics*, 47(4), 920-933.
- Huang, G.-B. (2013). Extreme Learning Machines. (E. Cambria, Ed.) *IEEE Intelligent Systems*, 30-59.
- Huang, G.-B. (2015). What are Extreme Learning Machines? Filling the Gap Between Frank Rosenblatt's Dream and John von Neumann's Puzzle. *Cong Comput*, 263-278.
- Huang, G.-B., Zhou, H., Ding, H., Ding, X., & Zhang, R. (2012). Extreme Learning Machine for Regression and Multiclass Classification. *IEEE Transactions on systems, man, and cybernetics - Part B : Cybernetics*, 42(2), 513-529.
- Huang, G.-B., Zhu, Q.-Y., & Siew, C.-K. (2006). Extreme learning machine: Theory and applications. *Neurocomputing*, 489 - 501.
- INEC. (2016). *Instituto Nacional de Estadísticas y Censos*. Recuperado el 14 de Noviembre de 2017, de <http://www.ecuadorencifras.gob.ec/transporte/>
- INEN. (2011). *Servicio Ecuatoriano de Normalización*. Recuperado el 01 de 12 de 2017, de Instituto Ecuatoriano de Normalización: http://www.normalizacion.gob.ec/wp-content/uploads/downloads/2013/11/rte_4_1_1.pdf
- Intelligent transportation system architecture and standards. (2008). *U.S Government Publishing Office*. Recuperado el 13 de diciembre de 2017, de 23 CFR 940 : <https://www.gpo.gov/fdsys/granule/CFR-2008-title23-vol1/CFR-2008-title23-vol1-part940>
- John, V., Yoneda, B., Lui, Z., & Mita, S. (2014). Traffic Light Recognition in Varying Illumination using Deep Learning and Saliency Map. *IEEE 17th International Conference on Intelligent Transportation Systems (ITSC)*, 2286-2291.
- Kaplan Berkaya, S., Gunduz, H., Ozsen, O., Akinlar, C., & Gunal, S. (2016). On circular traffic sign detection and recognition. *Expert Systems with Applications*, 67-75.
- Koncar, A., Janben, H., & Saman, H. (2007). Gabor wavelet similarity maps for optimising hierarchical road sign classifiers. *Pattern Recognition Letters*, 260 - 267.
- Kuo, W.-J., & Lin, C.-C. (2007). Two-Stage Road Sign Detection and Recognition. *IEEE Multimedia and Expo*, 1427 - 1430.
- Lilo Castellano, J., Mora Jimenez, I., Figuera Pozuelo, C., & Rojo Alvarez, J. (2014). Traffic sign segmentation and classification using statistical learning methods. *Neurocomputing*, 286-299.

- López, R. (07 de 05 de 2014). *¿Qué es y cómo funciona “Deep Learning”?* Recuperado el 10 de 02 de 2018, de <https://rubenlopezg.wordpress.com/2014/05/07/que-es-y-como-funciona-deep-learning/>
- Mahadevan, I. (22 de 03 de 2017). *Quora*. Recuperado el 17 de 11 de 2017, de <https://www.quora.com/Why-are-radial-basis-function-based-neural-networks-more-efficient-at-universal-function-approximation-than-sigmoid-function-based-neural-networks>
- Maldonado Bascón, S., Acevedo Rodríguez, J., Lafuente Arroyo, S., Fernández Caballero, A., & López-Ferreras, F. (2010). An optimization on pictogram identification for the road-sign recognition task using SVMs. *Computer Vision and Image Understanding*, 373 - 383 .
- Malik, Z., & Siddiqi, I. (2014). Detection and Recognition of Traffic Signs from Road Scene Images. *IEEE 12th International Conference on Frontiers of Information Technology (FIT)*, 330 - 335.
- Mercedes-Benz. (2013). *Mercedes-Benz the best or nothing*. Recuperado el 10 de 02 de 2018, de <https://www.mercedes-benz.com/en/mercedes-benz/innovation/mercedes-benz-intelligent-drive/>
- Mobileye. (2017). *Mobileye an Intel company*. Recuperado el 10 de 02 de 2018, de <https://www.mobileye.com/our-technology/adas/>
- Nguwi, Y.-Y., & Kouzani, A. Z. (2008). Detection and classification of road signs in natural environments. *Neural Computing and Applications*.
- OMS. (Mayo de 2017). *WHO*. Recuperado el 04 de Diciembre de 2017, de Lesiones causadas por el tránsito: <http://www.who.int/mediacentre/factsheets/fs358/es/>
- Prieto, M. S., & Allen, A. R. (2009). Using self-organising maps in the detection and recognition of road signs. *Image and Vision Computing*, 673 - 683.
- Ruta, A., Porikli, F., Watanabe, S., & Li, Y. (2011). In-vehicle camera traffic sign detection and recognition . *Machine Vision and Applications*, 359 – 375.
- Schulz-Mirbach, H. (1995). Invariant features for gray scale images. *17 DAGM - Symposium "Mustererkennung"*.
- Shi, J.-H., & Lin, H.-Y. (2017). A Vision System for Traffic Sign Detection and Recognition. *IEEE Industrial Electronics (ISIE)*, 1596-1601.
- Stallkamp, J., Schlipsing, M., Salmen, J., & Igel, C. (2012). Man vs. computer: Benchmarking machine learning algorithms for traffic sign recognition. *Neural Networks*, 323 - 332.
- Universidad Autónoma de Barcelona. (2018). *Coursera Inc*. Recuperado el 05 de 01 de 2018, de Coursera: <https://www.coursera.org/learn/deteccion-objetos>

- Wahyono, & Jo, K.-H. (2014). A Comparative Study of Classification Methods for Traffic Signs Recognition. *IEEE International Conference on Industrial Technology (ICIT)*, 614 - 619.
- World Health Organization, (. (2017). *Global Status Report on Road Safety*. World Health Organization.
- Yang, X., Qu, Y., & Fang, S. (2012). Color fused multiple features for traffic sign recognition. *Internet Multimedia Computing and Service*, 84 - 87.
- Yin, S., Ouyang, P., Liu, L., & Wei, S. (2015). Fast Traffic Sign Recognition with a Rotation Invariant Binary Pattern Based Feature. *Sensors*, 2161-2180.
- Zabihi, S., Zabihi, S., Beauchemin, S., & Bauer, M. (2017). Detection and recognition of traffic signs inside the attentional visual field of drivers. *IEEE Intelligent Vehicles Symposium (IV)*, 583 - 588.
- Zaklouta, F., & Stanculescu, B. (2011). Warning Traffic Sign Recognition using a HOG-based K-d Tree. *IEEE Intelligent Vehicles Symposium (IV)*, 1019-1024.
- Zaklouta, F., & Stanculescu, B. (2014). Real-time traffic sign recognition in three stages. *Robotics and Autonomous Systems*, 16-24.
- Zhu, Y., Wang, X., Yao, C., & Bai, X. (2013). Traffic sign classification using two-layer image representation. *IEEE International Conference on Image Processing*, 3755 - 3759.