



IMPLEMENTACIÓN DE UN ALGORITMO PARA LA DETECCIÓN DE SEÑALES DE TRÁNSITO DEL ECUADOR: PARE, CEDA EL PASO Y VELOCIDAD

IMPLEMENTATION OF AN ALGORITHM FOR ECUADORIAN TRAFFIC SIGN DETECTION: STOP, GIVE-WAY AND VELOCITY CASES

Marco Flores-Calero^{1,2,*}, Cristian Conlago³, Jhonny Yunda³,
Milton Aldás⁴, Carlos Flores⁵

Resumen

Este artículo presenta un prototipo de un sistema embarcado en un vehículo para la detección de señales de tránsito (SDST). Por lo tanto, un nuevo enfoque para la construcción de un SDST se presenta usando las siguientes innovaciones, i) un método eficiente de segmentación por color para la generación de regiones de interés (ROI) basado en los algoritmos k -NN, con $K_m - means$, ii) una nueva versión del descriptor HOG para la extracción de características, y iii) el entrenamiento del algoritmo SVM no-lineal para multclasificación. El enfoque propuesto ha sido probado sobre un subconjunto de las señales de tránsito ecuatorianas de regulación (Pare, Ceda el paso y Velocidad). Varios experimentos han sido desarrollados en condiciones reales de conducción en varias ciudades ecuatorianas, bajo tres condiciones de iluminación: normal, soleado y nublado. Este sistema ha mostrado un desempeño global del 98,7 % para la segmentación, 99,49 % para la clasificación y una precisión global del 96 % en la detección.

Palabras clave: accidentes, Ecuador, HOG, $k - NN$, $K_m - means$, señales de tránsito, SVM, Pare, Ceda el paso, Velocidad.

Abstract

This paper presents a prototype for a traffic sign detection system (TSDS) on-board a moving vehicle. Therefore, a new approach to the development of an TSDS is presented, using the following innovations: i) an efficient method of color segmentation for the generation of regions of interest (ROIs) based on k -NN with $K_m - means$, ii) a new version of the HOG descriptor for feature extraction and iii) SVM training for stage multi-classification. The proposed approach has been specialized and tested on a subset of regulatory Ecuadorian signs (Stop, Give-way and Speed). Many experiments have been carried out in real driving conditions, under different lighting changes such as normal, sunny and cloudy. This system has showed a global performance of 98.7% for segmentation, 99.49% for classification and an accuracy of 96% for detection.

Keywords: Accidents, Ecuador, HOG, $k - NN$, $K_m - means$, SVM, Traffic sign, Stop, Give way, Velocity.

^{1,*}Departamento de Eléctrica y Electrónica, Universidad de las Fuerzas Armadas-ESPE. Sangolquí – Ecuador. Autor para correspondencia ✉: mjflores@espe.edu.ec, <http://orcid.org/0000-0001-7507-3325>

²Departamento de Sistemas Inteligentes, Tecnologías I&H. Latacunga, Ecuador.

³Carrera de Ingeniería en Electrónica, Automatización y Control, Universidad de las Fuerzas Armadas-ESPE <http://orcid.org/0000-0002-7772-5259>, <http://orcid.org/0000-0003-0498-9656>

⁴Facultad de Ingeniería Civil y Mecánica, Universidad Técnica de Ambato, Ambato – Ecuador. <http://orcid.org/0000-0003-2726-4092>

⁵Servicio de Investigación de Accidentes de Tránsito (SIAT), Policía Nacional del Ecuador, Latacunga – Ecuador. <http://orcid.org/0000-0003-2131-6883>

Recibido: 02-04-2018, aprobado tras revisión: 21-05-2018

Forma sugerida de citación: Flores-Calero, M.; Conlago, C.; Yunda, J.; Aldás, M. y Flores, C. (2018). «Implementación de un algoritmo para la detección de señales de tránsito del Ecuador: Pare, Ceda el paso y Velocidad». INGENIUS. N.º 20, (julio-diciembre). pp. 9-20. DOI: <https://doi.org/10.17163/ings.n20.2018.01>.

1. Introducción

1.1. Notación

La notación usada a lo largo de este artículo se presenta en la Tabla 1.

Tabla 1. Notación

Nombre	Siglas
K-nearest neighborhood	k-NN
Método de partición en Km medias	Km-means
Support Vector Machine	SVM
Principal Component Analysis	PCA
Support vector regresion	SVR
Convolutional Neural Network	CNN
Extrem Learning Machine	ELM
Multi-Layer Perceptron	MLP
Adaptive Boosting	Adaboost
Histogram of Oriented Gradient	HOG
Pyramidal Histogram of Oriented Gradient	PHOG
Aggregate Channel Features	ACF
Speeded Up Robust Features	SURF
Integral Channel Features	ICF
Discrimiative Codeword Selection	DSC
Region Of Interest	ROI
Espacio de color Red, Green, Blue	RGB
Espacio de color Luminancia, con crominancia Cb y Cr	YCbCr
Espacio de color Luminance, a* entre rojo y verde y b* entre amarillo y azul	L*a*b*
Espacio de color Hue, Saturation, Intensity	HSI
Espacio de color Hue, Saturation, Value	HSV
Receiver Operating Characteristic	ROC
Area under a ROC curve	AUC
Sistemas de detección de señales de tránsito	SDST

1.2. Motivación

Las señales de tránsito tienen como objetivo el ayudar al movimiento ordenado y seguro de los actores, permitir un continuo flujo del tránsito tanto de vehículos como de peatones. Cada una de estas señales presenta instrucciones, las cuales proporcionan información acerca de rutas, destinos, puntos de interés, prohibiciones, alertas, etc. Estas señales deben ser respetadas por todos los usuarios viales con la finalidad de evitar inesperados y lamentables accidentes, y sobre todo, contar con una circulación confiable y segura [1]. 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, por lo que es fundamental para los conductores tener en cuenta la velocidad establecida por las señales de tránsito [2].

Actualmente, el Ecuador dispone de la mejor red vial de Sudamérica [3], sobre esta se ubican las señales de tránsito reglamentarias de Pare y Ceda el paso y Velocidad, en las intersecciones viales, redondeles y aproximaciones por vías secundarias. A pesar de esta importante infraestructura vial supera la tasa de muertes en accidentes de tránsito con un 3,14 % sobre

la media de los países de la región andina. Así, los accidentes de tránsito son un problema constante, debido a varios factores críticos, como la imprudencia de los conductores al conducir con exceso de velocidad y al no respetar las señalizaciones de tránsito [4]. En el año 2015, el 13,75 % de todos los accidentes de tránsito sucedieron en las intersecciones viales [5] generando el 8,14 % de las personas fallecidas bajo este percance. Por otra parte, 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 [2].

Los SDST toman cada vez mayor importancia [6, 7] porque pueden ayudar en la prevención y en la reducción de los accidentes de tránsito [8]. Sin embargo, estos sistemas aún están lejos de ser perfectos, y deben ser especializados por países, adaptados a las particularidades del diseño de la señalética de tránsito de cada nación [9].

Por lo tanto, en esta investigación se presenta un SDST especializado en tres tipos de señales de tránsito del Ecuador como son Pare, Ceda el paso y Velocidad. El poder detectarlas es importante porque permite alertar al conductor de que atravesará una zona con alto potencial de choque con otro vehículo. En el caso del disco Pare, el conductor debe detenerse completamente; en el caso de Ceda el paso, el conductor debe entrar en vigilia, y en el caso de velocidad el conductor debe respetar los límites de velocidad de 50 km/h y 100 km/h, en zonas urbanas y de autopista, respectivamente. La señal de velocidad de 50 km/h es el límite más cotidiano en ambientes urbanos y la de 100 km/h en autopistas.

Para la implementación de SDST se han utilizado modernas técnicas de visión por computador e inteligencia artificial con el fin de cubrir todos los casos que se presentan en la conducción durante el día, como son: variabilidad de la iluminación, oclusión parcial y deterioro de las señales.

El resto del documento está organizado de la siguiente manera: la segunda sección corresponde a los trabajos previos en la detección de señales de tránsito. En el apartado tres un nuevo sistema para la detección de señales de tránsito para el caso de las señales de tránsito ecuatorianas de Pare, Ceda el paso y Velocidad. Luego, la siguiente sección exhibe los resultados experimentales en condiciones reales de conducción. Finalmente, la última parte está dedicada a las conclusiones y los trabajos futuros.

2. Materiales y métodos

2.1. Trabajos previos

Para el desarrollo de sistemas de detección automática de las señales de tránsito se suele dividir al problema

en dos partes, segmentación y reconocimiento/clasificación [10].

- a) En el caso segmentación, una de las características predominantes, en el espectro visible, es el color, donde se han utilizado espacios de color y distintas técnicas de visión por computador para generar regiones con alta posibilidad de contener una señal de tránsito. Tanto es así que la mayoría de las técnicas basadas en color buscan ser robustas frente a las variaciones de iluminación durante el día, en distintos escenarios como pueden ser soleados, nublados, etc. Así Salti *et al.* [11] han utilizado tres espacios de color derivados de RGB, el primero para resaltar las señales de tránsito con predominancia de los colores azules y rojos, el segundo es para las señales con rojo intenso y el tercero para los azules vivos. Li *et al.* [12] han construido un espacio donde resaltan los objetos dominados por los colores azul-amarillo y verde-rojo, sobre el cual, utilizando el algoritmo de agrupamiento K-means [13] construyen un método de clasificación por color para la generación de ROI. Nguyen *et al.* [6] han utilizado el espacio HSV con varios umbrales para generar un conjunto de ROI buscando colores rojos y azules. Lillo *et al.* [14] han utilizado los espacios $L^*a^*b^*$ y HSI para detectar señales donde predominan los colores rojo, blanco y amarillo, usando las componentes a^* y b^* han construido un clasificador para estos colores. Chen and Lu [15] han utilizado multiresolución y técnicas AdaBoost para fusionar dos fuentes de información, visual y localización espacial; en la visual construyen dos espacios de color basados en RGB denominados mapas salientes de color, en la espacial han usado el gradiente con distintas orientaciones. Finalmente, Han *et al.* [16] han usado la componente H del espacio HSI, para generar un intervalo, donde resaltan las señales de tránsito, y construir una imagen en grises donde se localizan las ROI. Villalón *et al.* [17] han implementado un filtro usando el espacio de color RGB normalizado, sobre el cual, mediante el cálculo de parámetros estadísticos han generado las regiones de color rojo y así han obtenido las ROI.
- b) En el escenario reconocimiento/clasificación se han utilizado algunos métodos para la extracción de características en conjunto con un algoritmo de aprendizaje-máquina [18–20], para así clasificar y reconocer los distintos tipos de señales. Esta etapa se divide en dos partes: i) método de extracción de características y, ii) elección del algoritmo de clasificación. En el primer caso se tiene una amplia variedad de propuestas. Así, Salti *et al.* [11], Huang *et al.* [21], Shi and Li [22]

han utilizado el descriptor HOG [23] con tres variantes especializadas en señales de tránsito. Li *et al.* [12] han usado el descriptor PHOG, que es una variación de HOG en sentido piramidal. Lillo *et al.* [14] han implementado la extracción de características usando la transformada discreta de Fourier. Han *et al.* [16] han utilizado el método SURF [24]. Chen and Lu [15] emplearon DSC iterativo para la generación del vector de características. Mongoose *et al.* [9] implantaron en conjunto ICF y ACF para generar las características. Pérez *et al.* [10] han usado la técnica PCA para la reducción de la dimensión y la elección de características dominantes. Finalmente, Lau *et al.* [25] han usado una ponderación de los píxeles vecinos para resaltar las características del objeto de interés. En la segunda cuestión, los algoritmos preferidos son: SVM [20], [13], utilizado en los trabajos de Salti *et al.* [11], Li *et al.* [12], Lillo *et al.* [14] y Shi and Li [26]. SVR usado en Chen and Lu [15], [20] implementado en las investigaciones de Han *et al.* [16]. Redes neuronales artificiales, empleadas por Huang *et al.* [21] con el caso ELM y Pérez *et al.* [10] con la implementación MLP. Adaboost con árboles de decisión utilizados en el trabajo de Mogelmoose *et al.* [9]. Villalón *et al.* [17] han desarrollado una plantilla estadística basada en un modelo en probabilidad ajustado sobre los espacios YCbCr y RGB normalizado. En los últimos años, las técnicas basadas en aprendizaje profundo van ganando mayor importancia, tanto es así que CNN y sus variaciones son utilizadas para la clasificación automática, donde el vector de características se extrae sin la intervención humana directa, en este caso están los trabajos de Lau *et al.* [25], Zhu *et al.* [27] y Zuo *et al.* [28].

- c) Respecto a las bases de datos de señales de tránsito se puede mencionar que cada país tiene sus propias normativas en cuanto a su señalética, divide en las categorías de informativas, obligatorias, prohibitivas y advertencia [9], [11], [14], [15], [27]. En la actualidad, las principales bases de datos, presentes en la bibliografía, corresponden a países como Alemania [10], [21], Italia [11], España [14], Japón [6], Estados Unidos [9], Suecia [27], Malasia [25]; aisladamente se tiene el caso de Chile [17]. Esta revisión bibliográfica demuestra que no existe información importante, y menos aún, confiable de los países en desarrollo, como es el caso del Ecuador, en lo que respecta a las bases de datos de señales de tránsito; esto genera un reto para levantar este tipo de información, que además debe ser relevante para garantizar la seguridad vial y el mantenimiento de la infraestructura vial.

2.2. Métodos para la construcción del sistema de detección de señales de tránsito

El esquema del sistema propuesto en esta investigación se presenta en la Figura 1, donde están las etapas de segmentación (localización) y reconocimiento (clasificación). En el proceso de segmentación se genera un

conjunto de ROI, que posteriormente será enviado a la etapa de clasificación para su reconocimiento. En esta propuesta únicamente se trabaja en el caso restringido de las señales de tránsito Pare, Ceda el paso y Velocidad de 50 km/h y 100 km/h. Estas señales tienen en común el color rojo, y pertenecen al tipo prohibición.

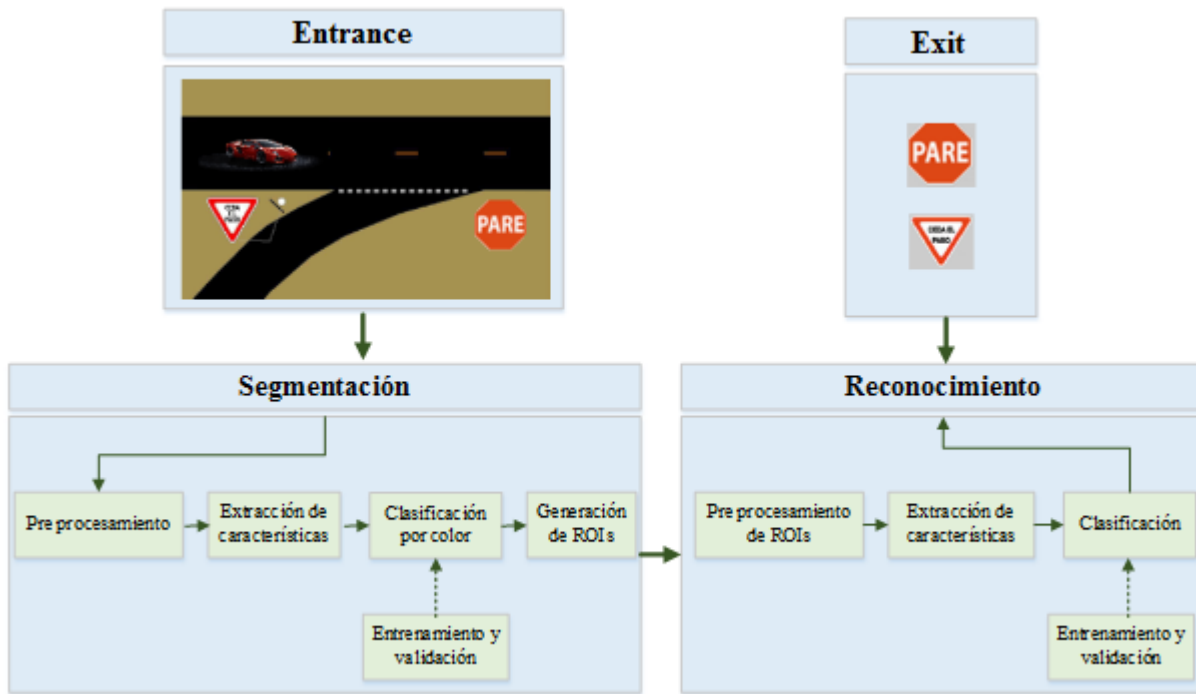


Figura 1. Esquema propuesto para la localización y reconocimiento de señales de tránsito en intersecciones viales en el Ecuador en el espectro visible, para los casos Pare y Ceda el paso; y su posterior extensión al caso de velocidad en 50 km/h y 100 km/h.

2.2.1. Segmentación por color y generación de ROI

La Figura 1 (izquierda) muestra el esquema de segmentación que se describe a continuación.

La segmentación se realiza discriminando el color rojo del fondo, es decir, del resto de colores. Experimentalmente se ha elegido el espacio de color RGB normalizado (RGBN) porque presenta una distribución más compacta en los canales B_n y G_n , cuyos valores se encuentran en los intervalos $[20; 90]$ y $[0; 90]$ respectivamente. La Figura 2(a) muestra la distribución del color rojo en función de las condiciones de iluminación, normal, soleado y oscuro. Figura 2(b) muestran las distribuciones de las clases, donde el rojo representa la clase de interés y el azul identifica la clase de no interés.

- 1) **Puntos representativos en el espacio B_n y G_n :** Para generar un número reducido de puntos representativos de cada clase se utiliza el algoritmo de agrupación K_m -means [19]; de esta manera, se obtienen K_m centroides para cada una de las clases. Utilizando los métodos de Calinski-Harabasz [29], Davies-Bouldin [30], Gap [31] y Silhouettes [32] se ha llegado a determinar experimentalmente el valor eficiente de K_m , obteniéndose los siguientes valores, 30 y 40 para las clases rojo y no rojo (otros colores), respectivamente. La Figura 2(b) muestra los centroides de las dos clases generadas con K_m . Para generar esta figura se han utilizado muestras en tres condiciones de iluminación: soleado, normal y oscuro.




Figura 2. Distribución del color en el espacio RGB normalizado B_n y G_n , (a) distribución en función de las condiciones de iluminación, (b) representación de las clases de interés y no interés, (c) gráfico de los centroides generadas con $K_m - means$.

- 2) **Diseño del clasificador basado en $k - NN$:**
Para diseñar este clasificador es importante ele-

gir un valor de adecuado que permita la mejora discriminación entre las clases de interés y el fondo. En este sentido, se ha usado el valor del área bajo la curva, conocido como índice AUC, de la curva ROC [33]. Los valores utilizado para este procedimiento están entre 1 y 8. La Tabla 2 muestra los resultados para elegir el mejor valor de k .

Tabla 2. Elección del parámetro k en $k - NN$

k	1	2	3	4
AUC	0.985	0.931	0.986	0.987
k	5	6	7	8
AUC	0.985	0.983	0.982	0.983

- 3) **Postprocesamiento de cuerpos:** Posteriormente, utilizando los operadores morfológicos de dilatación y erosión [26] se eliminan ciertos cuerpos que no cumplen con características específicas de tamaño para ser candidatos a señales de tránsito. Experimental se ha fijado varios umbrales para este procedimiento.
- 4) **Restricciones geométricas:** Finalmente, se eliminan los cuerpos que no cumplen la relación alto/ancho, usando umbrales determinados experimentalmente; en la Tabla 3 se presentan los parámetros necesarios en función de la distancia de referencia. Esta distancia es parte de la zona de riesgo de colisión de un vehículo.

Tabla 3. Características geométricas que debe cumplir una ROI sobre una imagen de tamaño 640×480 en función de la distancia de referencia

Característica	Valor mínimo	Valor máximo
Área	400 pixeles	10 000 pixeles
Relación ancho / alto	0,6	1,4
Distancia de referencia	20 metros	5 metros

2.2.2. Reconocimiento de las señales de tránsito

En esta etapa se clasifican las ROI provenientes de la etapa de segmentación, para determinar si corresponden a una señal de Pare, Ceda el paso, Velocidad u otro objeto que no sea de interés.

En la Figura 1 (derecha) se muestra el esquema de reconocimiento, el mismo que consta de las siguientes partes:

- 1) **Preprocesamiento de los candidatos:** Se transforma las imágenes correspondientes a las ROI a escala de grises, después se normalizan al tamaño 32×32 píxeles y posteriormente se realiza la ecualización del histograma para obtener una imagen con una distribución uniforme de los niveles de gris. Este proceso permite aumentar el contraste de la imagen y disminuir los cambios abruptos de iluminación.
- 2) **Extracción de características:** Se utiliza una nueva versión del descriptor HOG [34] para encontrar las características representativas de una señal de tránsito. La innovación desarrollada sobre este descriptor se centra en variar el tamaño de las celdas y las orientaciones, y encontrar la mejor combinación adaptada a las señales de tránsito. En este sentido, las celdas toman valores de 2×2 , 4×4 , 8×8 , 16×16 píxeles. La Figura 3 muestra esta forma de división en los cuatro casos. La orientación se obtiene dividiendo al rango de orientación sin signo de $[-90^\circ; 90^\circ]$ o $[-\frac{\pi}{2}; \frac{\pi}{2}]$ en 3, 6, 9, 12 y 15 intervalos.

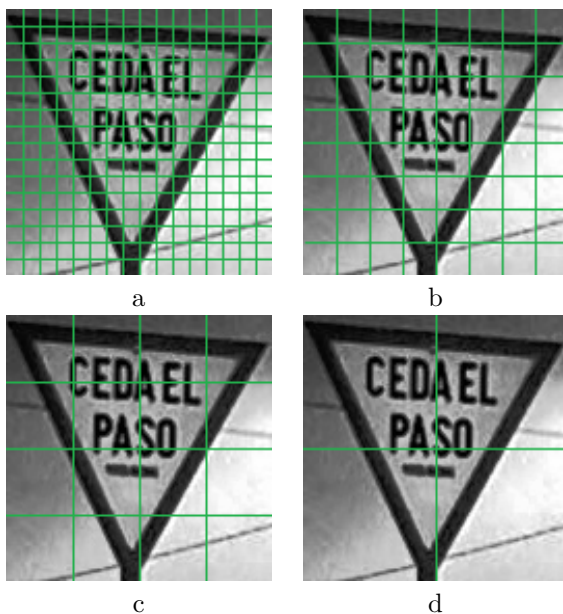


Figura 3. Variación del tamaño de celda sobre imágenes de tamaño 32×32 píxeles: (a) 2×2 , (b) 4×4 , (c) 8×8 (d) 16×16 .

- 3) **Entrenamiento del clasificador basado en SVM:** Se utiliza SVM [18–20] con tres núcleos diferentes para experimentar la mejor opción: lineal, polinómico y RBF. Para el entrenamiento se usan tres conjuntos de datos que corresponden a las señales Pare, Ceda el paso, Velocidad y otros elementos que no pertenecen a los casos anteriores.

Sobre esta gama de parámetros se escoge la mejor opción usando el índice AUC [33]. En total se evalúan 60 casos combinando los puntos 2 y 3, de los cuales se extraen los que generan mejores resultados en la siguiente sección.

3. Resultados y discusiones

3.1. Sistema de percepción y procesamiento

El sistema de detección de señales de tránsito total se presenta en la Figura 4. El sistema de percepción está compuesto por una cámara webcam con entrada USB a 25 fotogramas por segundo, una pantalla de visualización y un soporte para la cámara. El sistema de procesamiento es un computador instalado sobre el vehículo experimental ViiA. Este vehículo incorpora una fuente de poder de 12 V-120 AC que suministrar continuamente corriente eléctrica para el funcionamiento del sistema en carretera.



Figura 4. Sistema de detección de señales de tránsito del Ecuador, en los casos Pare, Ceda el paso y Velocidad (50 y 100), instalado sobre el parabrisas de un vehículo experimental.

Actualmente, este sistema es de fácil instalación en cualquier tipo de vehículo, y no interfiere con las labores de conducción debido a su reducido tamaño.

3.2. Base de datos de entrenamiento, validación y experimentación

Las bases de datos de entrenamiento y de validación han sido construidas con imágenes de señales de tránsito del Ecuador, tomadas en las ciudades de Latacunga, Ambato, Salcedo, Quito y Sangolquí, en escenarios reales de conducción, en distintas condiciones de iluminación durante el día. Estas condiciones corresponden a los casos de normal, soleado y nublado. Más detalles se encuentran en la Tabla 4.


Tabla 4. Condiciones ambientales para la adquisición de las imágenes

Ambiente	Tiempo real sobre ciudades y autopistas
Condiciones del clima	Normal, soleado y nublado
Tiempo de captura	5.30 a. m. a 7.30 p. m.
Velocidad de captura de cámara	25 fotogramas por segundo
Tamaño de la imagen	640 x 480 píxeles
Fondo de la imagen	Complejo, no fijo
Tamaño de las señales de tránsito	Diferente
Condiciones de las señales de tránsito	Desvanecido, borroso, dañado, ocluido
Tipo de señales de tránsito	Pare, Ceda el paso y Velocidad de 50 y 100

En la Tabla 5 se indica el tamaño de los conjuntos de entrenamiento y de validación obtenidos por medio del método de Holdout [35] y en la Figura 5 se observan varios ejemplos positivos y negativos.

Tabla 5. Tamaño de los conjuntos de entrenamiento y validación por las señales Pare, Ceda el paso y negativas

	Número de muestras					Total
	Pare	Ceda el paso	Vel. 50	Vel. 100	Negativas	
Entrenamiento	700	700	700	700	2800	5600
Validación	300	300	300	300	1200	2400
Total	1000	1000	1000	1000	4000	8000

**Figura 5.** Ejemplos de la base de datos de señales de tránsito del Ecuador en distintas condiciones de iluminación y de estado, (a) Pare, (b) Ceda el paso, (c) límite de 50 km/h, (d) límite de 100 km/h y (e) ejemplos negativos.

Para incrementar el tamaño del conjunto de entrenamiento se rotaron aleatoriamente las imágenes hasta obtener un total de cinco veces el tamaño original. De esta manera, se incrementa la variabilidad de la base de datos.

Posteriormente para verificar el funcionamiento del sistema se construyó una base de datos con videos en situaciones reales de conducción, en el espectro visible bajo distintas condiciones de iluminación. Esta base está constituida por cinco ejemplares en diferentes condiciones de iluminación, donde las señales han sido localizadas manualmente con fines de evaluación [33].

3.3. Análisis de resultados

Los resultados se pueden resumir en los siguientes puntos:

- 1) Para el caso de la segmentación por color, el algoritmo de clasificación genera un AUC de 0,986, con $k = 4$ y $K_m = 30$ para la clase de color rojo y $k = 4$ y $K_m = 30$ para la clase otros colores.
- 2) Para el caso de la clasificación, los mejores parámetros del descriptor HOG son celdas de 8×8 píxeles, bloques de 2×2 celdas con solapamiento simple, 9 orientaciones sin signo y SVM polinomial de parámetros $C = 215$, $r = 0$, $\gamma = 1/m$, con m es el tamaño del vector de características. En la Tabla 6 se presentan los resultados para el caso de 8×8 píxeles, donde el mejor resultado se encuentra resaltado en negrilla.

Tabla 6. Resultados de clasificación con características HOG con celdas de tamaño 8×8 píxeles en todas las orientaciones

Orientaciones	Tipo de núcleo		
	Lineal	Polinómico	RBF
3	0,9603	0,9913	0,9755
6	0,9784	0,9947	0,9834
9	0,9798	0,9949	0,9784
12	0,9762	0,9921	0,9827
15	0,9834	0,9971	0,9819

Para medir el poder de detección, la curva de la tasa de falsos negativos (taza de pérdida) *versus* la tasa de falsos positivos, en escala logarítmica en el rango de 0.01–1m [36], se presenta en la Figura 6, en ella se observa que el mejor desempeño se realiza en días normales con una tasa de pérdidas del 13 % y la peor ejecución es en días soleados con una tasa de pérdidas del 28 %.

El sistema tiene un excelente desempeño, con una precisión promedio del 96 %. La peor precisión se logra en condiciones soleadas, ya que el exceso de luz impide una correcta segmentación para la generación de ROIS, ver Tabla 7.




Figura 6. Curva DET del sistema de detección de señales de tránsito, separado en los distintos casos de iluminación y globalmente.

Tabla 7. Resultados del sistema de detección de señales de tránsito en diferentes escenarios de iluminación durante el día

	TRPa	TFNb	TRNc	TFPd	Exe	Prf
Día normal	0,87	0,13	0,997	0,003	0,98	0,97
Día soleado	0,72	0,28	0,995	0,005	0,97	0,9
Día nublado	0,79	0,21	0,997	0,003	0,97	0,96
Sistema total	0,81	0,19	0,997	0,003	0,98	0,96

a Tasa de reales positivos, b Tasa de falsos negativos
c Tasa de reales negativos, d Tasa de falsos positivos
e Exactitud, f Precisión

Varios ejemplos generados por el sistema se los puede observar en las Figuras 7, 8, 9 y 10. Las muestras se encuentran en diversas condiciones de iluminación durante el día, amanecer e inicio de la noche, al recorrer zonas urbanas y zonas de autopista alrededor de las ciudades de Quito y Sangolquí.



(a)




(b)




(c)


Figura 7. Resultados del sistema de detección de señales de tránsito en el caso Pare, durante un día soleado sobre una autopista; (a) imagen de entrada, (b) ROI y (c) detecciones.



(a)



(b)



(c)

Figura 8. Resultados del sistema de detección de señales de tránsito en los casos Pare y Ceda el paso, durante un día oscuro en zona urbana; (a) imagen de entrada, (b) ROI y (c) detecciones.



(a)



(b)



(c)

Figura 9. Resultados del sistema de detección de señales de tránsito en el caso de velocidad de 50, durante un día oscuro (al amanecer) en zona urbana; (a) imagen de entrada, (b) ROI y (c) detecciones.



(a)



(b)



(c)

Figura 10. Resultados del sistema de detección de señales de tránsito en el caso de velocidad de 100, durante un día oscuro en zona urbana; (a) imagen de entrada, (b) ROI y (c) detecciones.

3.4. Tiempos de cómputo

En la Tabla 8 se presenta el tiempo de cómputo del sistema global.

Tabla 8. Tiempos de cómputo total del sistema de detección de señales de tránsito del Ecuador en el espectro visible en los casos Pare, Ceda el paso.

Etapa	Tiempo promedio (ms)
Captura	1,75
Segmentación	28,79
Reconocimiento	14,05
Visualización	1.75
Tiempo total	46,34

Estos resultados son los valores promedios del procesamiento de imágenes de tamaño píxeles, distribuidos de la siguiente manera: 9999 en soleado, 14 744 en normal y 12 442 en nublado.

A partir de estos resultados experimentales se puede verificar que los tiempos de cómputo; en los casos de segmentación y de reconocimiento, son bastante reducidos y por ende competitivos para ser parte de aplicaciones en sistemas en tiempo real.

4. Conclusiones y trabajos futuros

En este trabajo de investigación, en el campo de los sistemas de asistencia a la conducción con énfasis en la detección de las señales de tránsito, se realizaron los siguientes aportes originales:

- La construcción de una nueva base datos para el reconocimiento de señales de tránsito del Ecuador, en los casos Pare, Ceda el paso y Velocidad. Esta información está disponible para el libre uso de la comunidad científica.
- El desarrollo de un nuevo método de segmentación por color para la generación de ROI utilizando el clasificador k -NN junto con el algoritmo de agrupamiento $K_m - means$. Esta implementación cubre eficientemente los escenarios de iluminación normal, soleado y oscuro, durante el día. Además, se incluye la distancia como un parámetro de referencia para la preselección de ROI. De esta manera, esta propuesta alcanza una tasa de clasificación del 98,7 % en los píxeles de interés y el fondo.
- La implementación de una nueva versión del descriptor HOG que consiste en celdas de 8×8 píxeles, bloques de 2×2 celdas con solapamiento simple y 9 orientaciones sin signo. La tasa de clasificación es del 99,49 usando SVM con núcleo polinómico.

- La construcción de un sistema de detección de las señales de tránsito del Ecuador, especializado en los casos Pare y Ceda el paso. La curva DET indica que su desempeño es del 96 %, de manera que es competitivo respecto a las propuestas presentes en el estado del arte.
- La construcción de un asistente de ayuda a la conducción que trabaja en tiempo cuasirreal, es decir, a 21,58 fotogramas por segundo, es un sistema de fácil instalación en un vehículo de uso cotidiano.

Para el futuro se extenderá esta metodología a todas las señales de tránsito del tipo prohibición del Ecuador, donde se encuentran el resto de las señales de límites de velocidad, para área urbana y autopistas. Finalmente, indicar que se introducirá un método para comprobar y comparar la calidad del clasificador, en este sentido, se está preparando un método basado en ELM.

Agradecimientos

El vehículo utilizado para el desarrollo de una parte significativa de este proyecto ha sido facilitado por la empresa Tecnologías I&H, a ella nuestro agradecimiento. Además, agradecemos a los revisores anónimos por su valioso aporte ya que han contribuido significativamente en la mejora de este manuscrito.

Referencias

- [1] INEN, *RTE INEN 004-1:2011. Señalización vial. Parte 1. Señalización vertical*, Instituto Ecuatoriano de Normalización Std., 2011. [Online]. Available: <https://goo.gl/pSQimH>
- [2] OMS. (2018) Lesiones causadas por el tránsito. Organización Mundial de la Salud. [Online]. Available: <https://goo.gl/q1Mbuf>
- [3] K. Schwab, “The global competitiveness report 2015–2016,” World Economic Forum, Tech. Rep., 2015. [Online]. Available: <https://goo.gl/FvJVkb>
- [4] ANT. (2017) Siniestros septiembre 2017. Agencia Nacional de Tránsito, Ecuador. [Online]. Available: <https://goo.gl/MZ1d75>
- [5] ——. (2015) Siniestros octubre 2015. Agencia Nacional de Tránsito, Ecuador. [Online]. Available: <https://goo.gl/Pc4JfM>
- [6] B. T. Nguyen, S. J. Ryong, and K. J. Kyu, “Fast traffic sign detection under challenging conditions,” in *2014 International Conference on Audio, Language and Image Processing*, July 2014, pp. 749–752. DOI: <https://doi.org/10.1109/ICALIP.2014.7\protect \kern +.1667em\relax 009\protect \kern +.1667em\relax 895>.

- [7] H. Gomez-Moreno, S. Maldonado-Bascon, P. Gil-Jimenez, and S. Lafuente-Arroyo, "Goal evaluation of segmentation algorithms for traffic sign recognition," *IEEE Transactions on Intelligent Transportation Systems*, vol. 11, no. 4, pp. 917–930, 2010. DOI: <https://doi.org/10.1109/TITS.2010.2054084>.
- [8] A. Shaout, D. Colella, and S. Awad, "Advanced driver assistance systems - past, present and future," in *Computer Engineering Conference (ICENCO), 2011 Seventh International*, Dec 2011, pp. 72–82. DOI: <https://doi.org/10.1109/ICENCO.2011.6\protect \kern +.1667em\relax 153\protect \kern +.1667em\relax 935>.
- [9] A. Møgelmoose, D. Liu, and M. M. Trivedi, "Detection of u.s. traffic signs," *IEEE Transactions on Intelligent Transportation Systems*, vol. 16, no. 6, pp. 3116–3125, Dec 2015. DOI: <https://doi.org/10.1109/TITS.2015.2433019>.
- [10] S. E. Perez-Perez, S. E. Gonzalez-Reyna, S. E. Ledesma-Orozco, and J. G. Avina-Cervantes, "Principal component analysis for speed limit traffic sign recognition," in *2013 IEEE International Autumn Meeting on Power Electronics and Computing (ROPEC)*, Nov 2013, pp. 1–5. DOI: <https://doi.org/10.1109/ROPEC.2013.6\protect \kern +.1667em\relax 702\protect \kern +.1667em\relax 716>.
- [11] S. Salti, A. Petrelli, F. Tombari, N. Fioraio, and L. D. Stefano, "Traffic sign detection via interest region extraction," *Pattern Recognition*, vol. 48, no. 4, pp. 1039–1049, 2015. DOI: <https://doi.org/10.1016/j.patcog.2014.05.017>.
- [12] H. Li, F. Sun, L. Liu, and L. Wang, "A novel traffic sign detection method via color segmentation and robust shape matching," *Neurocomputing*, vol. 169, pp. 77–88, 2015. DOI: <https://doi.org/10.1016/j.neucom.2014.12.111>.
- [13] T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, S. S. B. Media, Ed., 2009. [Online]. Available: <https://goo.gl/5kPw8C>
- [14] J. Lillo-Castellano, I. Mora-Jiménez, C. Figueroa-Pozuelo, and J. Rojo-Álvarez, "Traffic sign segmentation and classification using statistical learning methods," *Neurocomputing*, vol. 153, pp. 286–299, 2015. DOI: <https://doi.org/10.1016/j.neucom.2014.11.026>.
- [15] T. Chen and S. Lu, "Accurate and efficient traffic sign detection using discriminative adaboost and support vector regression," *IEEE Transactions on Vehicular Technology*, vol. 65, no. 6, pp. 4006–4015, June 2016. DOI: <https://doi.org/10.1109/TVT.2015.2500275>.
- [16] Y. Han, K. Virupakshappa, and E. Oruklu, "Robust traffic sign recognition with feature extraction and k-nn classification methods," in *2015 IEEE International Conference on Electro/Information Technology (EIT)*, May 2015, pp. 484–488. DOI: <https://doi.org/10.1109/EIT.2015.7\protect \kern +.1667em\relax 293\protect \kern +.1667em\relax 386>.
- [17] G. Villalón-Sepúlveda, M. Torres-Torriti, and M. Flores-Calero, "Sistema de detección de señales de tráfico para la localización de intersecciones viales y frenado anticipado," *Revista Iberoamericana de Automática e Informática Industrial RIAI*, vol. 14, no. 2, pp. 152–162, 2017. DOI: <https://doi.org/10.1016/j.riai.2016.09.010>.
- [18] C. Cortes and V. Vapnik, "Support-vector networks," *Machine Learning*, vol. 20, no. 3, pp. 273–297, Sep 1995. DOI: <https://doi.org/10.1007/BF00994018>.
- [19] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern Classification*, 2nd ed., J. W. Sons, Ed., 2012. [Online]. Available: <https://goo.gl/pvWsE9>
- [20] N. Cristianini and J. Shawe-Taylor, *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*. Cambridge University Press, 2000. DOI: <https://doi.org/10.1017/CBO9780511801389>.
- [21] Z. Huang, Y. Yu, and J. Gu, "A novel method for traffic sign recognition based on extreme learning machine," in *Proceeding of the 11th World Congress on Intelligent Control and Automation*, June 2014, pp. 1451–1456. DOI: <https://doi.org/10.1109/WCICA.2014.7\protect \kern +.1667em\relax 052\protect \kern +.1667em\relax 932>.
- [22] J. H. Shi and H. Y. Lin, "A vision system for traffic sign detection and recognition," in *2017 IEEE 26th International Symposium on Industrial Electronics (ISIE)*, June 2017, pp. 1596–1601. DOI: <https://doi.org/10.1109/ISIE.2017.8\protect \kern +.1667em\relax 001\protect \kern +.1667em\relax 485>.
- [23] N. Dalal, "Finding People in Images and Videos," Theses, Institut National Polytechnique de Grenoble - INPG, 2006. [Online]. Available: <https://goo.gl/ZZCd7F>
- [24] H. Bay, A. Ess, T. Tuytelaars, and L. V. Gool, "Speeded-up robust features (SURF)," *Computer Vision and Image Understanding*, vol. 110, no. 3,

- pp. 346–359, 2008. DOI: <https://doi.org/10.1016/j.cviu.2007.09.014>.
- [25] M. M. Lau, K. H. Lim, and A. A. Gopalai, “Malaysia traffic sign recognition with convolutional neural network,” in *2015 IEEE International Conference on Digital Signal Processing (DSP)*, July 2015, pp. 1006–1010. DOI: <https://doi.org/10.1109/ICDSP.2015.7>
- [26] G. P. Martinsanz and J. M. de la Cruz García, *Visión por computador: imágenes digitales y aplicaciones*, R.-M. S. E. y Publicaciones, Ed., 2008. [Online]. Available: <https://goo.gl/YDjJG6>
- [27] Y. Zhu, C. Zhang, D. Zhou, X. Wang, X. Bai, and W. Liu, “Traffic sign detection and recognition using fully convolutional network guided proposals,” *Neurocomputing*, vol. 214, pp. 758–766, 2016. DOI: <https://doi.org/10.1016/j.neucom.2016.07.009>.
- [28] Z. Zuo, K. Yu, Q. Zhou, X. Wang, and T. Li, “Traffic signs detection based on faster r-cnn,” in *2017 IEEE 37th International Conference on Distributed Computing Systems Workshops (ICDCSW)*, June 2017, pp. 286–288. DOI: <https://doi.org/10.1109/ICDCSW.2017.34>.
- [29] T. Calinski and J. Harabasz, “A dendrite method for cluster analysis,” *Communications in Statistics*, vol. 3, no. 1, pp. 1–27, 1974. DOI: <https://doi.org/10.1080/03610927408827101>.
- [30] D. L. Davies and D. W. Bouldin, “A cluster separation measure,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. PAMI-1, no. 2, pp. 224–227, April 1979. DOI: <https://doi.org/10.1109/TPAMI.1979.4766909>.
- [31] T. Robert, W. Guenther, and H. Trevor, “Estimating the number of clusters in a data set via the gap statistic,” *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, vol. 63, no. 2, pp. 411–423. DOI: <https://doi.org/10.1111/1467--9868.00>
- [32] P. J. Rousseeuw, “Silhouettes: A graphical aid to the interpretation and validation of cluster analysis,” *Journal of Computational and Applied Mathematics*, vol. 20, pp. 53–65, 1987. DOI: [https://doi.org/10.1016/0377-0427\(87\)90125-7](https://doi.org/10.1016/0377-0427(87)90125-7).
- [33] T. Fawcett, “Roc graphs: Notes and practical considerations for researchers,” Tech. Rep., 2004. [Online]. Available: <https://goo.gl/Sr6tFj>
- [34] N. Dalal and B. Triggs, “Histograms of oriented gradients for human detection,” in *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR’05)*, vol. 1, June 2005, pp. 886–893. DOI: <https://doi.org/10.1109/CVPR.2005.177>.
- [35] R. Kohavi, “A study of cross-validation and bootstrap for accuracy estimation and model selection,” in *Proceedings of the 14th International Joint Conference on Artificial Intelligence - Volume 2*, ser. IJCAI’95. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1995, pp. 1137–1143. [Online]. Available: <https://goo.gl/j5rXZX>
- [36] A. Martin, G. Doddington, T. Kamm, M. Ordowski, and M. Przybocki, “The det curve in assessment of detection task performance,” 1997, pp. 1895–1898. [Online]. Available: <https://goo.gl/nf6MZu>