

Ecuadorian Regulatory Traffic Sign Detection by Using HOG Features and ELM Classifier

Marco Flores-Calero, Miltón Aldás, Jonathan Vargas and María José Ayala

Abstract—This article presents an algorithm for Ecuadorian regulatory traffic signs detection, under extreme lighting conditions during the day. The method is composed of the following modules, i) video stabilization to reduce vertical oscilation, ii) a method to for obtaining regions of interest (ROIs) based on color information and geometric restrictions, iii) a two-stage multi classification algorithm, based on Extreme Learning Machine (ELM) and HOG descriptor, to classify by form and content. A database of Ecuador's regulatory traffic signs has also been created. It has more than 47,000 images of Ecuadorian road signs divided into 16 classes. The experimental results, from the recognition module, generate an accuracy of 99,85 %, and a sensitivity of 99,78 % in the first stage, and an accuracy of 96,71 % and a sensitivity of 94,16 % in the second stage. In addition, its robustness was compared with two other classifiers, in order to choose the one with the best performance in terms of accuracy and low computational cost. This system works at 24 frames per second, and it was tested in real driving conditions, from 6:00 a.m. until 7:00 p.m., on the streets of several cities and highways of Ecuador.

Index Terms—Traffic accidents, regulatory traffic sign, ELM, HOG, Ecuador.

I. INTRODUCCIÓN

La Organización Mundial de la Salud (OMS) indica que los accidentes de tráfico están entre las principales causas de muerte a nivel mundial, con el 2,4 % del total de muertes, con un costo aproximado, por país, del 1 al 3 % del PIB [1].

Los principales factores que causaron estos percances, fueron la distracción frente al volante, y el exceso de velocidad. La normativa de límites de velocidad en áreas urbanas en varios países de Latinoamérica es estricta, y limitada a 50 km/h. No obstante, en el caso del Ecuador, éste supera la tasa de muertes en accidentes de tráfico con un 3,14 % sobre la media de los países de la región andina [2].

Para atenuar esta problemática están las señales de tráfico, que son signos colocados en la vía pública para advertir, informar, ordenar o reglamentar el comportamiento de los usuarios viales. Existen varios tipos, uno de ellos son las reglamentarias, cuya función es indicar a los usuarios las obligaciones, las limitaciones o las prohibiciones especiales que deben respetar en la vía [3].

M. Flores-Calero is with Department of Intelligent Systems, I&H Tech, Latacunga (Cotopaxi), Ecuador and Universidad de las Fuerzas Armadas-ESPE, Av. Gral. Rumiñahui, s/n, PBX 171-5-231B, Sangolquí (Pichincha), Ecuador and Yachay Tech. Urcuquí (Imbabura), Ecuador, mjflores@espe.edu.ec. ORCID: <https://orcid.org/0000-0001-7507-3325>

M. Aldás is with grupo de investigación COESVI, Facultad de Ingeniería Civil y Mecánica, Universidad Técnica de Ambato campus Huachi, Avenida Los Chasquis y Calle Río Payamino, Ambato, Tungurahua, Ecuador.

J. Vargas and M. Ayala are IT consultants in the private sector.

Por otra parte, en los últimos años se están desarrollando los denominados Sistemas Avanzados de Asistencia a la Conducción (ADAS, *Advanced Driver Assistance System*), cuyo objetivo es trabajar cooperativamente con el conductor para mejorar la seguridad vehicular. Entre ellos están los Sistemas de Detección de Señales de Tráfico (SDST) [4], los mismos que deben cumplir estrictos protocolos de operación para anticiparse y evitar situaciones peligrosas; consecuentemente, en su funcionamiento se deben tomar en cuenta bajas tasas de error y altas tasas de precisión, eficiencia y eficacia en todas las situaciones de conducción [4]–[6].

En este escenario, las condiciones climáticas son un factor preponderante a tomar en consideración durante el diseño de los SDST; porque éstas generan cambios bruscos y extremos de iluminación, incrementando la dificultad de detección de las señales de tráfico.

En este trabajo, se entiende por iluminación extrema las situaciones donde existe abundante sol o niebla o lluvia o baja iluminación, durante el día. Estas condiciones son típicas de las tres regiones climáticas continentales del Ecuador, que son Sierra, Litoral y Amazonía [7].

Por consiguiente, la contribución de este trabajo es el presentar un SDST especializado en las Señales de Tráfico Reglamentarias del Ecuador, con énfasis en el reconocimiento bajo condiciones extremas de iluminación, en el espectro visible, con alta exactitud y un reducido costo computacional.

El resto del documento está organizado de la siguiente manera. La segunda sección corresponde a los trabajos previos en el reconocimiento de señales de tráfico. En el apartado tres se presenta un nuevo sistema para la detección y el reconocimiento de señales de tráfico reglamentarias del Ecuador en condiciones extremas de iluminación. El método utilizado para la extracción de características se basa en el descriptor HOG [8], y la técnica utilizada, para la etapa de clasificación, es ELM [9], [10]. Luego, la siguiente sección exhibe los resultados experimentales, donde se incluye una exhaustiva comparación del rendimiento de varios clasificadores y la evaluación del detector en su conjunto. Finalmente, la última parte está dedicada a las conclusiones y los trabajos futuros.

II. ESTADO DEL ARTE

El desarrollo de los SDST es un tema abierto y activo de investigación, debido la dificultad intrínseca que involucra el trabajar en ambientes reales de conducción, donde existe un sinúmero de cambios inesperados de las condiciones de la escena vial [4], [11], [12].

Una de las técnicas preferidas para localizar candidatos a señales de tráfico es el color. Bajo esta característica se busca

robustez frente a las variaciones de iluminación durante el día [13]. Entre los principales aportes están: Salti et al. [14] han utilizado los espacios de color para resaltar las señales de tráfico con predominancia de los colores azules y rojos. Li et al. [5] han construido dos espacios donde resaltan los colores azul-amarillo y verde-rojo, sobre los cuales, utilizado el algoritmo k -means han construido un método para la generación de ROIs [15]. Nguyen et al. [11] han utilizado el espacio HSV con varios umbrales para generar un conjunto de ROIs buscando colores rojos y azules. Lillo et al. [16] han utilizado los espacios $L^*a^*b^*$ y HSI para detectar señales donde predominan los colores rojo, blanco y amarillo. Con el algoritmo k -means han construido un clasificador usando únicamente las componentes a^* y b^* [15]. Chen y Lu. [17] han utilizado multiresolución y 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. Kaplan et al. [18] han utilizado el algoritmo de detección circular y un conjunto de umbrales sobre el espacio RGB para localizar ROIs. Finalmente, Han et al. [19] han usado la componente H del espacio HSI, donde han generado un intervalo, donde resaltan las señales de tráfico, para construir una imagen en grises donde se localizan las ROIs.

Para la extracción de características se conoce que Salti et al. [14], Huang et al. [12] han utilizado el descriptor HOG [8] con tres variantes. Kaplan et al. [18] también usan HOG junto con BLP (*Local Binary Patterns*) y el filtro de Gabor, Li et al. [5] han usado el descriptor PHOG, que es una variación de HOG. Lillo et al. [16] han implementado la extracción de características usando la transformada discreta de Fourier. Han et al. [19] utilizaron el método SURF [20]. Chen y Lu. [17] han utilizado DSC (*Discriminative Codeword Selection*) iterativo para la generación de características. Mogelmoose et al. [6] han implementado ICF (*Integral Channel Features*) y ACF (*Aggregate Channel Features*). Perez et al. [21] usaron PCA (*Principal Component Analysis*) para la reducción de la dimensión y la elección de características. Finalmente, Lau et al. [22] usaron una ponderación de los píxeles vecinos.

Los algoritmos de clasificación preferidos son: SVM [15], usado en los trabajos de Salti et al. [14], Li et al. [5], [16], Lillo et al. [16], Kaplan et al. [18]. SVR en Chen y Lu [17], k -NN [15] implementado en las investigaciones de Han et al. [19]. Redes neuronales artificiales, empleadas por Huang et al. [12] con el caso ELM y Perez et al. [21] con la implementación MLP (*Multi-Layer Perceptron*). Adaboost junto con árboles de decisión han sido utilizados por Mogelmoose et al. [6].

En los últimos años, las técnicas de aprendizaje profundo han ido adquiriendo importancia, debido a su capacidad de aprender e inferir sin necesidad de un conocimiento especializado previo, pero con alto costo computacional. Entre las principales técnicas, aplicadas a las señales de tráfico, están CNN (*Convolutional Neural Network*), R-CNN *Region proposals with CNN*), RBFNN (*Radial Basis Function Neural Network*), FCN (*Fully Convolutional Network*) [22]–[25].

En estos casos, las tasas de exactitud de varios sistemas, en

porcentaje, son las siguientes: Nguyen et al. [11] 92,5, Salti et al. [14] 78,21, Li et al. [5] 94,5, Han et al. [19] 97,54, Chen y Lu. [17] 97,78, Huang et al. [12] 93,21, Mogelmoose et al. [6] 98,98, Kaplan et al. [18] 97,04, Perez et al. [21] 98,9, Lau et al. [22] 99,0 y Zhu et al. [23] 97,69. Esto implica que aún existe, un desafiante, margen para mejorar en esta área de investigación.

A la fecha, las principales bases de datos de señales de tráfico, corresponden a países como Alemania [12], [14], [18], [21], Italia [14], Reino Unido [26], España [16], Japón [11], Estados Unidos [6], Suecia [23] o Malaysian [22]. Esto demuestra que existe la necesidad de generar bases de datos de señales de tráfico de los países de América Latina, para desarrollar SDSTs especializados en la región.

Por último cabe indicar que las principales empresas automotrices han ubicado a los SDST entre los dispositivos más importantes en el ámbito de la seguridad vehicular, el avance tecnológico y el confort [27]–[30], motivo por el cual, los vehículos modernos y de alta gama están incorporando SDST, los mismos que aún funcionan en situaciones muy específicas de la escena vial.

III. MÉTODOS Y MATERIALES

El esquema del sistema planteado se exhibe en la Fig. 1, donde están las etapas de estabilización de video, obtención de ROIs basada en color (detección de color) y la multi-clasificación de señales (reconocimiento).

En este esquema tienen especial relevancia las dos últimas etapas, que corresponden al proceso de obtención de un conjunto de ROIs, y la etapa de multi-clasificación, para el reconocimiento del tipo de señal.

A. Estabilización de Video

Las oscilaciones y vibraciones de la cámara (OVC), inducidas por el movimiento normal del vehículo en carreteras urbanas o autopistas, genera distorsiones en la imagen.

Para reducir el OVC se ha implementado el método de estabilización de video (MEV) basado dos fotogramas consecutivos, el filtro de Kalman y un filtro pasa bajo, pero modificado para atenuar las oscilaciones verticales [31], [32]. MEV entra en funcionamiento inmediatamente luego de la captura, previo a ingresar a la etapa de segmentación.

B. Obtención de ROIs Basado en Color

Para localizar las posibles posiciones de las señales de tráfico, dentro de la imagen, se ha utilizado una característica intrínseca, como es el color; por ello se han elegido los espacios de color RGB normalizado (RGBn) y HSV [33].

Así, el método consiste de dos pasos, el primero es usar k -NN con k -means para generar una máscara con los píxeles representativos del color rojo, sobre el espacio RGBn [34]. Luego se construye un filtro de color sobre el espacio HSV usando la ecuación (1). Así, con estas dos máscaras se eliminan los píxeles que no corresponden al color rojo, mediante la operación lógica AND.

$$\text{Píxel rojo si } \begin{cases} 0 \leq H \leq 10 \cup 120 \leq H \leq 250 \\ 65 \leq S \leq 255 \\ 75 \leq V \leq 255 \end{cases} \quad (1)$$

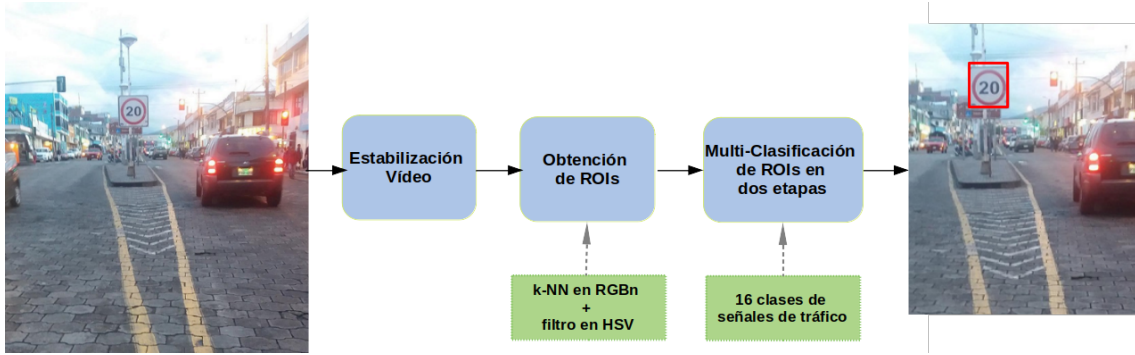


Fig. 1. Esquema del sistema de detección y reconocimiento de las señales reglamentarias del Ecuador.

Los umbrales de (1) se calcularon experimentalmente, sobre una base de datos, con más de doscientos setenta mil píxeles, de color rojo, en distintas condiciones de iluminación [34].

Posteriormente se aplican varias operaciones morfológicas, de dilatación y erosión, y restricciones geométricas, dadas en la tabla I, para eliminar el ruido y obtener un conjunto de ROIs. Estos umbrales se determinaron de manera experimental.

TABLA I
RESTRICCIONES GEOMÉTRICAS PARA LA OBTENCIÓN DE ROIS.

Parámetros	Valor mínimo	Valor máximo
Área	120 px	5060 px
Ancho (w)	5 px	84 px
Alto (h)	24 px	60 px
Relación w/h	0,2	1,4
Distancia w/h	5 m	35 m

C. Multi-clasificación de las Señales de Tráfico Reglamentarias

En la Fig. 2 se presenta el esquema del algoritmo para la multi-clasificación (reconocimiento) de las señales de tráfico reglamentarias del Ecuador:

El reconocimiento de las señales de tráfico es un problema de multi-clasificación, por lo tanto es necesario utilizar un algoritmo que soporte este tipo de retos, así ELM se presenta como una de las mejores alternativas [9], [10].

C1. Acondicionamiento de la imagen:

- **Pre-procesamiento:** Es la etapa en la que se ingresa la ROI con la imagen en color y se transforma a escala de grises, luego se redimensiona a una escala estándar de 32×32 píxeles, determinado como el mejor tamaño para extraer características de señales de tráfico. Para mejorar la calidad de la imagen y evitar la variación de la iluminación, ésta ha sido ecualizada para así normalizar el brillo y aumentar el contraste [34].
- **Extracción de características:** En este caso se ha utilizado una nueva representación del descriptor HOG con los parámetros previamente determinados en [34], es decir, celdas de 8×8 píxeles, bloques de 2×2 celdas con

solapamiento simple, 9 orientaciones sin signo, con lo cual se genera un vector de características de tamaño 324.

C2. *Clasificador ELM:* ELM es una técnica emergente de aprendizaje máquina que aprende miles de veces más rápido que las técnicas de aprendizaje profundo, a la vez que conserva varias ventajas como rápida operación y fuerte capacidad de generalización [35]. En esencia, ELM es una plataforma unificada de aprendizaje, no iterativo, del tipo red neuronal SLFNs (*Single-Layer Feed-Forward Neural Networks*), que viene representada por (2).

$$f_L(\mathbf{x}) = \mathbf{h}(\mathbf{x})\beta \quad (2)$$

donde $\beta = [\beta_1, \dots, \beta_L]^T$ es el vector de pesos entre las capas oculta y de salida, $\mathbf{h}(\mathbf{x}) = [h_1(\mathbf{x}), \dots, h_L(\mathbf{x})]^T$ es el vector de salida de la capa oculta con respecto a la entrada \mathbf{x} , de dimensión d . Mediante $\mathbf{h}(\mathbf{x})$ se mapean los datos del espacio d -dimensional al espacio L -dimensional, H , denominado espacio de características ELM [36].

En la práctica, la función $h_j(\mathbf{x}) = G(\mathbf{a}_j, b_j, \mathbf{x})$ es la salida del j -ésimo nodo oculto, y es la denominada función de transferencia; \mathbf{a}_j y b_j son los parámetros aleatorios de aprendizaje del j -ésimo nodo oculto, para $j = 1, 2, \dots, L$.

Para resolver la ecuación (2), en un problema específico, es necesario un conjunto de datos de entrenamiento $\{(\mathbf{x}_i, \mathbf{t}_i) : \mathbf{x}_i \in \mathbb{R}^d, \mathbf{t}_i \in \mathbb{R}^m, i = 1, \dots, N\}$, con \mathbf{x}_i el vector de características de entrada, \mathbf{t}_i el vector de objetivos de salida, y N el número de ejemplos de entrenamiento. De esta manera se tiene que $H = [\mathbf{h}^T(\mathbf{x}_1), \dots, \mathbf{h}^T(\mathbf{x}_N)]$.

La función de activación utilizada en (2) es la función Sigmoide, dada por (3):

$$h_i(\mathbf{x}) = G(\mathbf{a}_i, b_i, \mathbf{x}) = \frac{1}{1 + e^{-(\mathbf{a}_i \cdot \mathbf{x} + b_i)}} \quad (3)$$

Los parámetros aleatorios \mathbf{a}_i y b_i son generados a partir de la distribución uniforme continua.

Luego, para estimar β se usa el método de mínimos cuadrados, así $\beta^* = H^+ \mathbf{T}$, donde $\mathbf{T} = [t_1^T, \dots, t_N^T]$ y H^+ es la matriz inversa generalizada de Moore-Penrose.

C3. *Multi-clasificación de señales de tráfico reglamentarias con ELM:* La propuesta de este trabajo es un esquema de multi-clasificación que se compone de dos etapas que dan lugar a dos tipos de salida; la salida 1 tiene relación directa con las señales reglamentarias, y la salida 2 se especializa en las señales de velocidad.

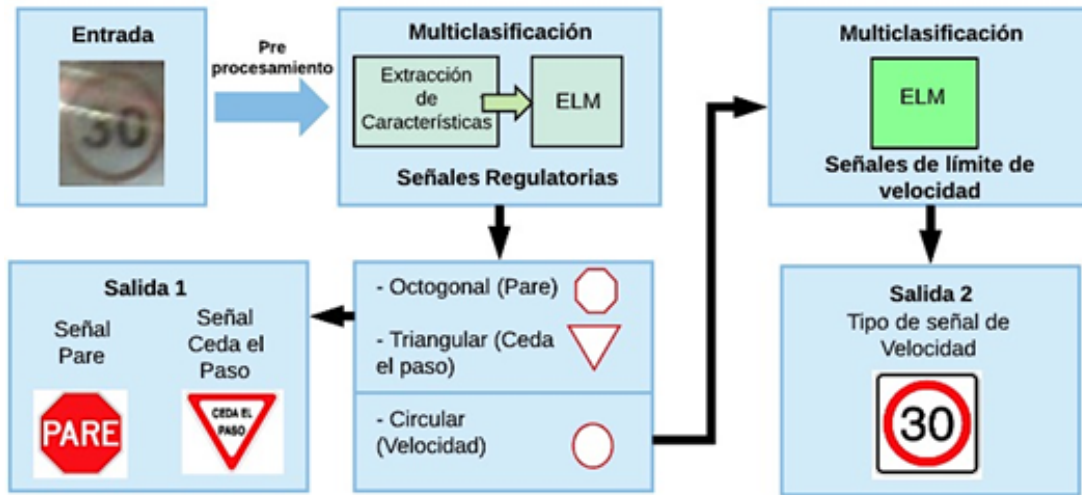


Fig. 2. Esquema del algoritmo de multi-clasificación de señales de tráfico reglamentarias (regulatorias) del Ecuador basado en el descriptor HOG y el clasificador ELM, en dos etapas.

La primera etapa genera como respuesta la clasificación de las clases **Pare**, **Ceda el Paso** y **Límite de Velocidad** dando como resultado un clasificador de tres clases de interés y una de no-interés; es decir, $t_i \in \mathbb{R}^{3+1}$. En esta etapa se genera la Salida 1 de la Fig. 2.

Para la multi-clasificación de señales reglamentarias se entrena ELM [9], [10] con una base de datos de señales de tráfico del Ecuador, detallada más adelante, en la Tabla II.

C4. Multi-clasificación de señales de límite de velocidad: La segunda etapa se alimenta de la primera, con el resultado de la clasificación de Límite de Velocidad, para clasificar las señales de límite de velocidad en los casos: 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, con lo cual se tienen 14 clases de interés y una de no-interés, es decir, $t_i \in \mathbb{R}^{14+1}$.

Para la multi-clasificación de las señales de límite de velocidad se entrena ELM [9], [10], junto con una base de datos restringida a las señales de límite de velocidad del Ecuador. Este clasificador entrega como respuesta el tipo de señal de límite de velocidad, que corresponde a la Salida 2 de la Fig. 2.

D. Base de Datos de Entrenamiento, Validación y Experimentación

En esta investigación se han construido dos conjuntos de datos; uno de ellos está relacionado con los píxeles, y el otro con las señales de tráfico (BDSTE).

La base de datos de píxeles de color rojo (BDPxR), necesarios para construir el método propuesto en [34], está formada de 270 mil píxeles de color rojo en varias condiciones de iluminación y 330 mil píxeles de otro color.

Por otra parte, la base de datos de señales de tráfico reglamentarias de Ecuador (BDSTRE) está constituida por 47,437 imágenes para entrenamiento y pruebas, en la Tabla II se describen en detalle las cantidades por cada clase.

Asimismo, en la Tabla III se muestra en detalle el número de imágenes por cada una de las señales de límite de velocidad.

TABLA II
BASE DE DATOS DE ENTRENAMIENTO Y DE PRUEBAS DE LAS SEÑALES DE TRÁFICO REGLAMENTARIAS DEL ECUADOR

	PARE	Ceda el Paso	Límite de Velocidad	Muestra Negativa	Total
Entrenamiento	700	500	10725	20000	31925
Prueba	300	243	4969	10000	15512

TABLA III
BASE DE DATOS DE ENTRENAMIENTO Y DE PRUEBAS DE LAS SEÑALES DE TRÁFICO DE LÍMITES DE VELOCIDAD DEL ECUADOR

Señal Velocidad	V10	V15	V20	V25	V30	V35	V40
Entrenamiento	1000	100	1000	25	1000	500	1000
Prueba	700	5	581	5	550	48	453
Señal Velocidad	V45	V50	V60	V70	V80	V90	V100
Entrenamiento	1000	1000	1000	1000	1000	1000	10725
Prueba	646	348	601	359	438	149	4969

Las bases de datos contienen imágenes capturadas en varias calles de distintas ciudades y autopistas del Ecuador continental, en días nublados, soleados, lluvioso y normales, desde el amanecer hasta el anochecer, en el horario de 6:00 a.m. a 7:00 p.m. En este escenario las condiciones de iluminación son extremas.

En la Fig. 3 se visualizan varias muestras que forman parte de la base de datos. Se puede observar que muchos de ellos tienen baja calidad, esto se debe a las condiciones del ambiente, la distancia de captura, y evidentemente, a las condiciones extremas de iluminación.

Para el entrenamiento de los clasificadores se han dividido aleatoriamente las bases de datos, BDPxR y BDSTRE, en



Fig. 3. Ejemplos de la base de datos de señales de tráfico reglamentarias en condiciones extremas de iluminación, (a) Pare, (b) Ceda el paso, (c-p) Velocidad.

conjuntos de entrenamiento, validación y prueba, al 60%, 20% y 20%, respectivamente.

IV. RESULTADOS EXPERIMENTALES

En esta sección se presentan los resultados experimentales del funcionamiento de los módulos que componen el sistema.

A. Métricas de Evaluación

Para medir la calidad del trabajo se han utilizado los siguientes métricas [37]: sensibilidad (3), razón de falsos positivos (4) y exactitud (5).

$$VPR = \frac{VP}{VP + FN} \quad (4)$$

$$FPR = \frac{FP}{FP + VN} \quad (5)$$

$$ACC = \frac{VP + VN}{VP + FN + FP + VN} \quad (6)$$

donde VP representa verdaderos positivos, FP es falsos positivos, VN es verdaderos negativos y FN indica falsos negativos.

Además, como indicador de calidad de la clasificación se ha usado el AUC (*Area Under the Curve*), cuyo valor está entre cero y uno. Mientras más cercano a uno (100%), el método es mejor.

B. Resultados del Algoritmo de Clasificación de Píxeles Rojos y Obtención de ROIs

En esta etapa se presentan los resultados de los siguientes casos, clasificación de los píxeles de color y obtención de ROIs.

- En la segmentación por color se obtuvieron $k_m = 40$ centroides para el rojo y $k_m = 50$ centroides para otros colores, respecto a k_m -means. El valor del parámetro de K-NN es 3 en ambos casos del color.
- Para medir la calidad de la clasificación de los píxeles rojos se ha calculado el AUC sobre la base de datos de prueba, cuyos resultados en las distintas condiciones de iluminación son: 98,21% en normales, 97,62% en nublado y 99,74% en soleado.
- Para medir la calidad del método de obtención de ROIs no existe una métrica establecida. Sin embargo, se puede

usar la métrica $IoU = Area(B_{ROI} \cap B_{gt}) / Area(B_{ROI} \cup B_{gt})$ donde B_{ROI} es la lista final de ROIs y B_{gt} es la lista verdadera de señales, obtenidas a mano. Si no existe intersección entre B_{ROI} y B_{gt} el valor es cero. Una ROI es verdadera si $IoU > 0,5$. Con estos antecedentes se concluye que el método propuesto es capaz de localizar el 98,89 % de las ROIs de las señales válidas presentes en la imagen.

En la Fig. 4 está un ejemplo completo del procedimiento para la obtención del conjunto de ROIs para la siguiente etapa.

C. Resultados del Algoritmo de Clasificación de Señales de Tráfico Reglamentarias

En el entrenamiento de ELM es importante definir el número óptimo de neuronas de la capa oculta, para tener un clasificador de calidad [9], [10]. Para determinar este parámetro se realizaron varios ensayos variando la cantidad de neuronas de la capa oculta, los resultados están en Tabla IV, donde se verifica que el número óptimo es 2000 neuronas, en función del mejor valor AUC.

TABLA IV
ELECCIÓN DEL NÚMERO DE NEURONAS DE LA CAPA OCULTA DE ELM EN FUNCIÓN DE LA MÉTRICA AUC.

Número de Neuronas	50	100	250	500	1000	1500	2000
AUC (%)	92,27	99,28	97,868	99,769	99,075	99,174	99,832

Para verificar el desempeño del algoritmo ELM se han desarrollado varios experimentos que consisten en: *i*) comparar el rendimiento de ELM versus Kd-Tree y SVM, *ii*) medir el tiempo de cómputo en cada caso.

D. Comparación de Clasificadores

Para comparar el rendimiento de ELM, respecto a otros clasificadores, se han implementado los algoritmos Kd-Tree y SVM sobre el mismo conjunto de datos.

En primer lugar, los resultados del AUC se encuentran en la Tabla V. En el caso de señales reglamentarias, ELM no presenta un desempeño superior respecto al resto de clasificadores. Para las señales de velocidad, ELM está entre Kd-Tree y SVM.

TABLA V
MÉTRICA AUC DE LA CLASIFICACIÓN DE LAS SEÑALES REGLAMENTARIAS Y LÍMITE DE VELOCIDAD, CON LOS CLASIFICADORES KD-TREE, SVM Y ELM.

	AUC (%)		
	Kd-Tree	SVM	ELM
Señales reglamentarias	99,73	99,83	99,83
Señales de velocidad	93,87	96,97	95,54

A continuación, en la Tabla VI se muestran los resultados de la primera etapa de multi-clasificación, donde se observa que los índices de sensibilidad y exactitud generan resultados similares en los tres casos.

TABLA VI
RESULTADOS DE LAS MÉTRICAS (%) AL EVALUAR LOS CLASIFICADORES KD-TREE, SVM Y ELM SOBRE LAS SEÑALES REGLAMENTARIAS.

	Kd-Tree	SVM	ELM
VPR	99,60	99,66	99,78
FPR	00,15	00,00	00,12
ACC	99,77	99,96	99,85

Luego en la Tabla VII se tienen los resultados de la segunda etapa de multi-clasificación, donde se nota que el índice de sensibilidad de ELM es comparable con SVM, pero con una exactitud inferior, respecto a los otros clasificadores.

TABLA VII
RESULTADOS DE LAS MÉTRICAS (%) AL EVALUAR LOS CLASIFICADORES KD-TREE, SVM Y ELM SOBRE LAS SEÑALES DE VELOCIDAD.

	Kd-Tree	SVM	ELM
VPR	88,61	94,37	94,16
FPR	00,88	00,43	03,09
ACC	98,37	99,20	96,71

E. Tiempo de Cómputo de los Clasificadores

El tiempo invertido para la etapa de entrenamiento de los clasificadores fue de 19,96 horas para ELM, 129,87 horas para SVM y 46,25 horas para Kd-Tree.

A continuación, en la Tabla VIII se muestran los tiempos de procesamiento, de cada una de las etapas, de clasificación en los tres casos.

TABLA VIII
TIEMPOS DE PROCESAMIENTO DE CADA UNA DE LAS ETAPAS DEL ALGORITMO DE MULTI-CLASIFICACIÓN.

Etapas	Tiempo de procesamiento (ms)		
	Kd-Tree	SVM	ELM
Preprocesamiento			0,1879
Descriptor HOG			0,1411
	Clasificadores		
Salida 1	12,476	15,931	1,057
Salida 2	20,444	139,350	6,822
Total	33,249	155,610	8,208

En esta ocasión ELM genera resultados superiores, en un 305 % y 1795 %, al compararlo con Kd-Tree y SVM, respectivamente.

El equipo utilizado para la fase experimental consiste en un computador provisto de un procesador Intel Core i5-3450 a 3,1GHz, 4 núcleos y 10Gb de RAM, con sistema operativo Ubuntu 18.04 LTS de 64 bits.

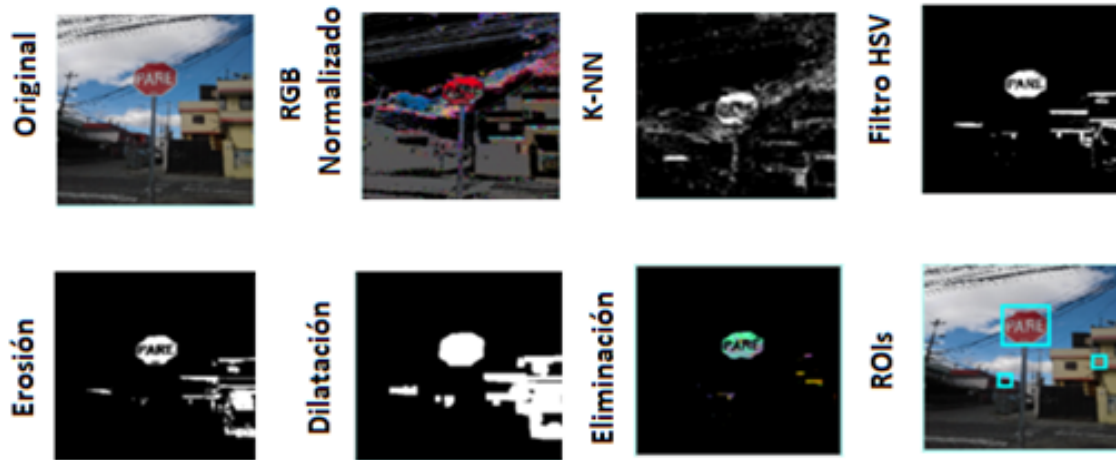


Fig. 4. Procedimiento para la obtención de ROIs. Fila superior: Captura de la imagen original, segmentación por color en RGBn con k -NN y filtro sobre HSV. Fila inferior: Operaciones morfológicas y restricciones geométricas para la eliminación del ruido, y finalmente el conjunto de ROIs.

F. Análisis de Resultados

Respecto a la clasificación se puede verificar que ELM, SVM y Kd-Tree generan resultados similares al comparar el AUC, la sensibilidad y la razón de falsos positivos; en la exactitud SVM tiene un desempeño ligeramente superior. Sin embargo, al comparar el tiempo de cómputo, ELM es superior, con el menor tiempo de procesamiento.

Con respecto al desempeño de ELM, al comparar con los resultados presentes en el estado del arte, se puede afirmar que es superior en todas las métricas. De esta manera, se verifica que ELM alcanza un equilibrio entre capacidad de reconocimiento y tiempo de cómputo.

G. Sistema de Detección de Señales de Tráfico

En esta oportunidad se ha procedido a unificar el software y el hardware para generar el prototipo del sistema de detección de señales de tráfico reglamentarias.

El software está compuesto por los distintos módulos del esquema dado por la Fig. 1.

El hardware está compuesto por una tarjeta de procesamiento, una pantalla de visualización y una cámara usb; todo esto va colocado en el parabrisas del vehículo experimental *ViiA*. En este diseño se ha tomado un cuidado especial para no obstruir la visibilidad y no interfiere con las labores de conducción.

Este sistema presenta un mAP (*mean Average Precision*) de 88,10 % para la detección, con el umbral de 0,5 para evaluar el índice *IoU* [38].

El tiempo de cómputo total, calculado sobre de imágenes de tamaño 640×480 píxeles [34], se presenta en la Tabla IX.

Esto implica que el SDST es capaz de procesar, en promedio, 24 fotogramas por segundo.

V. CONCLUSIONES Y TRABAJOS FUTUROS

El principal objetivo de este trabajo fue la construcción de un prototipo SDST para la detección de señales de tráfico reglamentarias del Ecuador.

En primer lugar, se incorporó un módulo de estabilización de video para mejorar la calidad de las imágenes que ingresan a las siguientes etapas. Posteriormente, se utilizó el color (sobre los espacios RGBn y HSV) para la obtención de un conjunto de ROIs en los distintos escenarios de iluminación durante el día. A continuación se implementó un clasificador basado en una versión mejorada del descriptor HOG y el algoritmo de clasificación ELM. La elección de ELM se realizó después de un exhaustivo trabajo experimental, donde demostró un desempeño equilibrado entre exactitud y tiempo de procesamiento.

Seguidamente se ensambló el hardware y el software para obtener el SDST; este prototipo trabaja a 24 fotogramas por segundo sobre imágenes de 640×480 píxeles, y es capaz de detectar señales entre los 5 y los 20 metros al frente del vehículo.

Para desarrollar los experimentos fue necesario construir una base de datos de señales de tráfico, en distintas condiciones climáticas durante el día. Actualmente, esta base contiene 16 clases de señales de tráfico.

A futuro se aumentará, el tamaño y el número de clases, de la base de datos, para recalcular los parámetros de los clasifi-

TABLA IX
TIEMPOS DE CÓMPUTO TOTAL DEL SISTEMA DE
DETECCIÓN DE SEÑALES DE TRÁFICO REGLAMENTARIAS
DEL ECUADOR.

Etapas	Tiempo promedio de procesamiento (ms)
Captura	1,750
Estabilización video	12,00
Segmentación (ROIs)	28,79
Reconocimiento	8,208
Visualización	1,750
Tiempo total	40,498

cadres y afinar el desempeño global del sistema. Además se incursionará en los algoritmos de Aprendizaje Profundo [39].

AGRADECIMIENTOS

El financiamiento, directo e indirecto, ha sido proporcionado por la empresa Tecnologías I&H.

Además, agradecemos a los revisores anónimos por su valioso aporte, porque han contribuido significativamente en la mejora de este manuscrito.

CONFLICTO DE INTERESES

Los autores declaran que no existe conflicto de intereses.

CONTRIBUCIÓN DE LOS AUTORES

El diseño de la investigación, la implementación parcial del software y el análisis de los resultados experimentales corresponden a M. Flores. La implementación parcial del software y el desarrollo de los experimentos recaen en J. Vargas y M. Ayala. La redacción y la revisión del manuscrito pertenecen a M. Aldás.

REFERENCIAS

- [1] Organización Mundial de la Salud. (2020) Plan Mundial para el Decenio de Acción para la Seguridad Vial 2011-2020. [Online]. Available: https://www.who.int/roadsafety/decade_of_action/plan/spanish.pdf
- [2] Agencia Nacional de Tránsito del Ecuador. (2017) Estadísticas de transporte terrestre y seguridad vial. [Online]. Available: <http://www.ant.gob.ec/>
- [3] Expertos en Siniestros. (2019) Significado de las señales de tráfico en España. [Online]. Available: <http://www.expertoensiniestros.es/significado-senales-de-trafico-en-espana/>
- [4] A.-T. Hoang, T. Koide, and M. Yamamoto, "Real-time speed limit traffic sign detection system robust automotive environments," *IEEE Transactions on Smart Processing and Computing*, pp. 237–250, 2015.
- [5] 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, May 2015.
- [6] A. Mogelmose, D. Liu, and M. M. Trivedi, "Detection of U.S. traffic signs," *IEEE Transactions on Intelligent Transportation Systems*, vol. 16, no. 6, pp. 1484–1497, December 2015.
- [7] I. Fundación Wikimedia. (2020) Regiones Naturales de Ecuador. [Online]. Available: https://es.wikipedia.org/wiki/Regiones_naturales_de_Ecuador
- [8] 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. IEEE, 2005, pp. 886–893.
- [9] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine: theory and applications," *Neurocomputing*, p. 489–501, 2006.
- [10] G.-B. Huang, "What are extreme learning machines? filling the gap between Frank Rosenblatt's dream and John von Neumann's puzzle," *Cognitive Computation*, p. 263–278, 2015.
- [11] B. T. Nguyen, J. Shim, and J. K. Kim, "Fast traffic sign detection under challenging conditions," *1 2014*, pp. 749–752.
- [12] Z. Huang, Y. Yu, and J. Gu, "A Novel Method for Traffic Sign Recognition based on Extreme Learning Machine," *Proceeding of the 11th World Congress on Intelligent Control and Automation*, pp. 1451–1456, 2015.
- [13] A. Guzmán and M. Chacón, "Analysis and trends on moving object detection algorithm techniques," *IEEE Latin America Transactions*, vol. 17, no. 11, pp. 1771–1783, 2019.
- [14] S. Salti, A. Petrelli, F. Tombari, N. Fioraio, and L. DiStefano, "Traffic sign detection via interest region extraction," *Pattern Recognition*, vol. 48, pp. 1039–1049, June 2015.
- [15] T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning*, 2nd ed. Springer, 2009.
- [16] J. Lillo, I. Mora, C. Figuera, and J. L. Rojo, "Traffic sign segmentation and classification using statistical learning methods," *Neurocomputing*, vol. 1, no. 153, pp. 286–299, November 2015.
- [17] 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, pp. 4006–4015, June 2016.
- [18] S. Kaplan-Berkaya, H. Gunduz, O. Ozsen, C. Akinlar, and S. Gunal, "On circular traffic sign detection and recognition," *Expert Systems with Applications*, vol. 48, pp. 67–75.
- [19] 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)*, 2015, pp. 484–488.
- [20] H. Baya, A. Essa, T. Tuytelaars, and L. Van Gool, "Speeded-Up Robust Features (SURF)," vol. 110, no. 3, pp. 346–359, June 2008.
- [21] 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)*, 2013, pp. 1–5.
- [22] M. M. Lau, K. H. Lim, and A. A. Gopalai, "Malaysia Traffic Sign Recognition on with Convolutional Neural Network," pp. 1006–1010, 2015.
- [23] 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*, July 2016.
- [24] J. P. N. Acilo, A. G. S. Dela-Cruz, and M. K. L. Kaw, "Traffic sign integrity analysis using deep learning," in *IEEE 14th International Colloquium on Signal Processing and Its Applications (CSPA)*, 2018.
- [25] H. He, L. Hui, and W. Gu, "Transferring digit classifier's features to a traffic sign detector," in *International Conference on Progress in Informatics and Computing (PIC)*, 2017.
- [26] J. Greenhalgh and M. Mirmehdi, "Real-time detection and recognition of road traffic signs," *IEEE Transactions on Intelligent Transportation Systems*, vol. 13, no. 4, pp. 1498–1506, December 2012.
- [27] Mercedes-Benz. (2013) Mercedes-benz the best or nothing. [Online]. Available: <https://www.mercedes-benz.com/en/mercedes-benz/innovation/mercedes-benz-intelligent-drive/>
- [28] Mobileye: An Intel Company. (2019) Speed limit indicator (sli). [Online]. Available: <https://www.mobileye.com/uk/fleets/technology/speed-limit-indicator/>
- [29] BMW Group. (2019) Speed limit information. [Online]. Available: http://content.bmwusa.com/microsite/3seriesActiveHybrid_2013/com/en/newvehicles/3series/sedan_active_hybrid/2011/showroom/safety/traffic_sign_recognition.html
- [30] Continental-Automotive. (2019) Traffic sign recognition. [Online]. Available: <https://www.continental-automotive.com/en-gl/Trucks-Buses/Vehicle-Chassis-Body/Advanced-Driver-Assistance-Systems/Functions/Traffic-Sign-Recognition>
- [31] L. Kejrival and I. Singh, "A hybrid filtering approach of digital video stabilization for UAV using Kalman and Low Pass Filter," *Procedia Computer Science*, vol. 93, pp. 359–366, 2016.
- [32] L. Bombini, P. Cerri, P. Grisleri, S. Scaffardi, and P. Zani, "An Evaluation of Monocular Image Stabilization Algorithms for Automotive Applications," in *Proceedings of the IEEE ITSC 2006 2006 IEEE Intelligent Transportation Systems Conference*, 2006, pp. 1562–1567.
- [33] M. K. Agoston, *Computer Graphics and Geometric Modeling: Implementation and Algorithms*, 2nd ed. Springer, 2005.
- [34] M. Flores-Calero, C. Conlago, J. Yunda, M. Aldás, and C. Flores, "Localización y reconocimiento de señales de tráfico del Ecuador: Casos Pare y Ceda el Paso," *ACI Avances en Ciencias e Ingenierías*, vol. 10, no. 16, pp. 146–159, December 2018.
- [35] L. Guo and A. Wee-Chung, "An improved extreme learning machine with parallelized feature mapping structures," in *International Conference on Digital Image Computing: Techniques and Applications (DICTA)*, 2016.
- [36] G. Huang, G.-B. Huang, S. Song, and K. You, "Trends in extreme learning machines: A review," *Neural Networks*, no. 61, pp. 32–48, 2015.
- [37] S. Bravo-Grau and J. P. Cruz, "Estudios de exactitud diagnóstica: Herramientas para su interpretación," *Revista Chilena de Radiología*, vol. 21, no. 4, pp. 158–164, 2015.
- [38] M. Everingham, L. Van Gool, C. K. I. Williams, J. Winn, and A. Zisserman, "The PASCAL Visual Object Classes (VOC) Challenge," *International Journal of Computer Vision*, vol. 88, pp. 303–338, 2010.
- [39] J. Salas, F. de Barros, and F. Martínez, "Deep learning: Current state," *IEEE Latin America Transactions*, vol. 17, no. 12, pp. 1925–1945, 2019.



Marco Flores-Calero es Ingeniero Matemático por la Escuela Politécnica Nacional (Ecuador) y doctor en Ingeniería Eléctrica, Electrónica y Automática por la Universidad Carlos III de Madrid (España). Actualmente, es profesor titular en la Universidad de las Fuerzas Armadas (Ecuador) y miembro externo de la Comisión Gestora de la Universidad de Investigación de Tecnología Experimental Yachay (Ecuador). Durante su trayectoria académica ha publicado sus trabajos científicos en revistas de prestigio internacional.



Milton Aldás Sánchez es Ingeniero Civil por la Universidad Técnica de Ambato, Ecuador, y doctor en Investigación Operativa por la Universidad Rey Juan Carlos, España. Actualmente es miembro del grupo de investigación COESVI, y académico en la Facultad de Ingeniería Civil y Mecánica de la Universidad Técnica de Ambato. Sus líneas de trabajo incluyen el uso de la investigación operativa en el análisis de datos y en los sistemas inteligentes de transporte.



Jonathan Vargas es licenciado en Ingeniería en Electrónica, Automatización y Control por la Universidad de las Fuerzas Armadas ESPE. Sus intereses de investigación son reconocimiento de patrones y aprendizaje máquina. En este momento trabaja en el sector privado como consultor de TICs.



María José Ayala es licenciada en Ingeniería en Electrónica, Automatización y Control por la Universidad de las Fuerzas Armadas ESPE. Actualmente trabaja en el sector privado en el desarrollo de TICs, con énfasis en aprendizaje máquina.