

Software para la clasificación y conteo de vehículos en autopistas basado en aprendizaje automático y visión artificial

E. Vázquez Benito^{1*}, C. Murrieta Vázquez², P. Ochoa Trujillo³

¹ Academia de Maestría en Sistemas Computacionales, Instituto Tecnológico Superior de Teziutlán, Fracción I y II S/N, Aire Libre, Teziutlán, Puebla. México.
emmanuel.vb@teziutlan.tecnm.mx

² Programa académico de Maestría en Sistemas Computacionales, Instituto Tecnológico Superior de Teziutlán, Fracción I y II S/N, Aire Libre, Teziutlán, Puebla. México.
19TE0009P@teziutlan.tecnm.mx

³ Academia de Ingeniería Informática, Instituto Tecnológico Superior de Teziutlán, Fracción I y II S/N, Aire Libre, Teziutlán, Puebla. México.
patricia.ot@teziutlan.tecnm.mx

Área de participación: *Sistemas Computacionales*

Resumen

El presente artículo describe el desarrollo del software para el conteo y clasificación de vehículos para autopistas en México, mediante el reconocimiento de imágenes utilizando visión artificial y machine learning; para el conteo de vehículos se utilizó la detección de contornos y el método de sustracción de fondo; para la clasificación se hace uso de detección de características tipo Haar, así como el algoritmo de Viola-Jones, Haar cascade, el desarrollo de la aplicación se consiguió utilizando la metodología OOHDM. Las pruebas se realizaron en el entronque de la Autopista Cardel-Poza Rica y la autopista Gutiérrez Zamora-Tihuatlán.

Con el uso de reconocimiento de imágenes para identificar y contar vehículos, se reduce el número de dispositivos que actualmente conforman un sistema aforador o de clasificación vehicular, mejorando su efectividad y desempeño. Actualmente esta tecnología, solo es aplicada para monitoreo de tráfico, detección de filas y sistemas inteligentes de transporte.

Palabras clave: *machine learning, visión artificial, clasificación, vehículos*

Abstract

This article describes the development of software for counting and classifying vehicles for highways in Mexico, through image recognition using artificial vision and machine learning; contour detection and the background subtraction method were used for counting vehicles; For the classification, detection of Haar-type characteristics is used, as well as the Viola-Jones algorithm, Haar cascade, the development of the application was achieved using the OOHDM methodology. The tests were carried out at the junction of the Cardel-Poza Rica Highway and the Gutiérrez Zamora-Tihuatlán Highway.

With the use of image recognition to identify and count vehicles, the number of devices that currently make up a gauge or vehicle classification system is reduced, improving its effectiveness and performance. Currently this technology is only applied for traffic monitoring, queue detection and intelligent transport systems.

Key words: *machine learning, artificial vision, classification, vehicles*

Introducción

Los sistemas de peaje en México utilizan en su mayoría sensores mecánicos incrustados en la superficie de rodamiento de los vehículos, para la clasificación y detección vehicular, el sobrepeso de los vehículos de carga a pesar de estar normado, es el principal responsable del deterioro de los mismos, en el mercado actual no existe una tecnología de reconocimiento de imágenes que sea precisa lo que incentiva la investigación publicada en el presente artículo.

En México, la tarificación para el cobro del peaje de un vehículo está basada en el número y tipo de ejes, los porcentajes de clasificación con los que deben cumplir los índices de desempeño en un sistema aforador son los siguientes: para motocicletas el porcentaje de desempeño debe ser mayor al 95%, para automóviles y camionetas con o sin remolque debe ser mayor a 97% en el caso de camiones rígidos debe ser mayor al 98% y para camiones articulados mayor al 99%.

En la plaza de cobro Totomoxtle II, perteneciente a la autopista Cardel – Poza Rica y la autopista Gutiérrez Zamora-Tihuatlán en el Estado de Veracruz, se utiliza un sistema aforador que muestra una baja eficiencia en la clasificación y conteo de vehículos, dicho sistema presenta fallas operativas y un alto porcentaje de errores, que lo ponen por debajo de los índices de desempeño requeridos en un sistema aforador, el mantenimiento correctivo al sistema de clasificación vehicular representa el cierre parcial de uno de los dos carriles de la autopista, provocando retrasos en el recorrido a los usuarios, además de la afectación a la superficie de rodamiento por la instalación de estructuras y ductos colocados en el piso que soportan a los sensores y el cableado. Por lo anterior se propone usar una tecnología opcional basada en visión artificial y aprendizaje automático que pueda integrarse como parte de un sistema de peaje que ya exista en el mercado y que se usa en casetas de peaje en México, que sea menos costosa en su implementación y mantenimiento, disminuyendo la infraestructura que hoy se utiliza.

La visión artificial también conocida como visión por computador (del inglés Computer Vision) incluye métodos para procesar, analizar y extraer información de imágenes o frames de videos, con el propósito de generar información a partir de representaciones numéricas. La visión por computador pretende reproducir el funcionamiento de la vista humana utilizando computadoras para el análisis de imágenes o videos obtenidos por medio de cámaras u otros dispositivos. (Barriga, 2017).

El aprendizaje automático o *Machine Learning*, es una rama de la inteligencia artificial que crea sistemas que aprenden de manera automática y que les permite a estos, aprender de los datos que recolectan. También permite entrenar modelos con los conjuntos de datos, sin tener que ser programados de manera explícita.

Para el desarrollo del software del presente artículo se hizo uso de Open CV, que es una biblioteca de visión por Computadora y aprendizaje automático de código libre que se usa para para el manejo de imágenes y detección de objetos. El lenguaje de programación aplicado es Phyton haciendo uso de la función findContours() y drawContours() para dibujar contornos en imágenes previamente binarizadas. Se utilizó el método HaarCascade con OpenCV, para realizar la clasificación de vehículos; para el conteo aplicando la substracción de fondo y detección de contornos, se consideró el número de píxeles que cambian dentro del área de interés definida, y que corresponde a la zona por donde cruzan los vehículos de la autopista.

Metodología

Tipo de investigación

El tipo de investigación en el presente trabajo es del tipo cuantitativo, el diseño de la investigación que se presenta es del tipo no experimental, se realizó un análisis transversal, la elección de este tipo de investigación se basa principalmente en que se requiere medir el porcentaje de error en cuanto a la clasificación y conteo de vehículos.

Selección de la muestra

El tipo de muestra es del tipo probabilística aleatoria.

Unidad de muestra

Las unidades de análisis son 744 vehículos que en promedio transitan entre las autopistas “Cardel-Poza Rica” y “Tihuatlán-Gtz. Zamora”, durante un período de 3 horas.

Identificación de variables

Las características para considerar el análisis de unidades de muestreo son: clase vehicular, dimensiones de las llantas, número de ejes y tipo de ejes. Se debe incluir el sentido de tránsito, dirección (origen-destino), cuerpo del carril, hora y fecha del vehículo analizado.

Instrumentos y técnicas.

El instrumento de medición es por observación sistemática regulada, se realizaron muestreos de vehículos mediante la aplicación desarrollada a las imágenes obtenidas en tiempo real de una cámara IP instalada en la autopista.

Un sistema de medición de aforo vehicular debe cumplir con el siguiente cálculo del porcentaje de error, de acuerdo con la norma de SCT:

Precisión en la clasificación requerido $\geq 99.5\%$ (mayor o igual a noventa y nueve punto cinco por ciento), es decir $Pcl_{req} = 99.5\%$

Precisión en la clasificación mínimo $\geq 95.0\%$ (mayor o igual a noventa y cinco punto cero por ciento), es decir $Pcl_{min} = 95.0\%$

$$Pcl_c < Pcl_{min} = DC\%inc(clasif) = 1$$

$$Pcl_c \geq Pcl_{req} = DC\%inc(clasif) = 0$$

$$Pcl_{min} \leq Pcl_c < Pcl_{req} = 1 - \frac{Pcl_c - Pcl_{min}}{Pcl_{req} - Pcl_c}$$

Desarrollo del software

El diseño del software se llevó a cabo con el uso de OOHDH por sus siglas en inglés *Object Oriented Hipermedia Design Method* que es una metodología de diseño hipermedia orientada a objetos, define las etapas de:

1. Obtención de requerimientos. Casos de uso.
2. Diseño conceptual.
3. Diseño navegacional.
4. Interfaces abstractas.
5. Implementación.

En las Ilustraciones 1,2,3 y 4 muestran los artefactos resultantes del seguimiento de la metodología OOHDH, en esta etapa se determinó como actor a la aplicación "Aforador vehicular inteligente", debido a que es el responsable de la detección y clasificación vehicular.

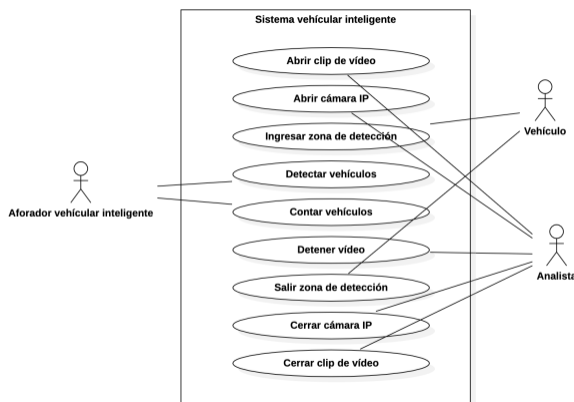


Ilustración 1. Etapa uno de OOHDH, obtención de requerimientos, diagrama de casos de uso general del sistema vehicular inteligente.

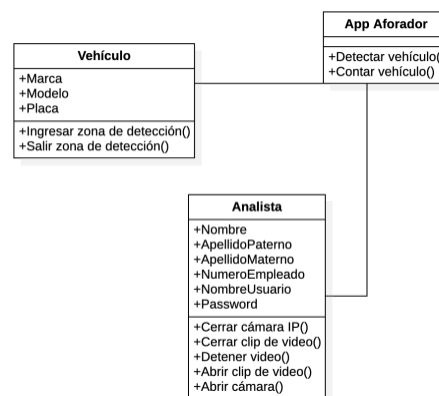


Ilustración 2. Etapa dos de OOHDH, diseño conceptual del sistema vehicular inteligente

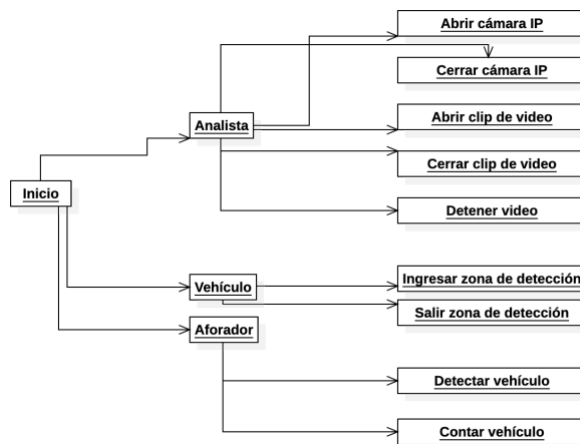


Ilustración 3. Etapa tres de OOHDM, diseño navegacional del sistema vehicular inteligente.

Como se observa en la Ilustración 4, se cuenta con una sola pantalla, desde la que se abrirá el video, ya sea desde un archivo de video o directo de una cámara IP y con la que interactúa el usuario.

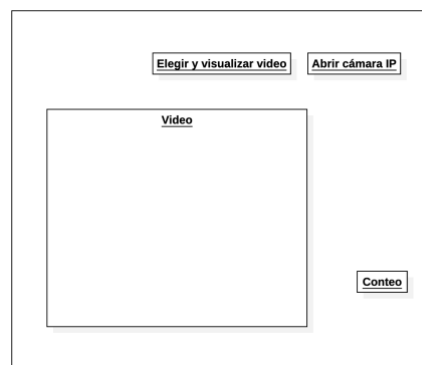


Ilustración 4. Etapa cuatro de OOHDM, diseño de interfaces abstractas.

La implementación es la etapa cinco de la metodología OOHDM, como resultado se obtuvo el siguiente software al que se le llamó “Aforador Vehicular Inteligente” que se muestra en la Ilustración 5.



Ilustración 5. Área de detección de vehículos redimensionada

Detección de contornos

Se hace uso de Open CV, que es una biblioteca de visión por computadora y machine learning de código abierto, útil para el manejo de imágenes, puede trabajar en conjunto con distintos lenguajes de programación, Open CV es utilizada sobre imágenes previamente binarizadas, para obtener los contornos se hace uso de la función `findContours()` y para dibujarlos `drawContours()`.



Ilustración 6. Detección de contornos aplicado en el software.

Substracción de fondos

Este método consiste en comparar las imágenes o fotogramas de un video con una imagen de fondo o de referencia, obtenidas de una cámara fija. De esta característica de donde proviene el nombre, también conocida como background subtraction. Los cambios en los elementos detectados representan objetos en movimiento. En 2010, este algoritmo fue utilizado en un trabajo previo para detectar y rastrear vehículos por Nicholas A. Mandellos, obteniendo resultados positivos.



Ilustración 7. Imágenes obtenidas con la aplicación propuesta utilizando el método de substracción de fondo.

HaarCascade

Para la clasificación de los vehículos se utilizó la clase `CascadeClassifier` de OpenCV. En 2001, Paul Viola y Michael Jones desarrollaron un método utilizando un enfoque de aprendizaje automático (machine learning) para la detección visual de objetos capaz de procesar objetos extremadamente rápidos y logrando una alta tasa de detección para la detección de rostros en una imagen.

El algoritmo se creó para la detección de rostros, hace uso de clasificadores que se agrupan de manera sucesiva y responden a un conjunto de características fundamentales que son: a) la imagen integral, para la representación de una imagen; b) un algoritmo de aprendizaje basado en Adaboost (Adaptative boosting), (Viola-Jones, 2001) que propone construir a una serie de clasificadores base, c) la creación de las estructuras a partir de los clasificadores, que combina en cascada de grupos de clasificación más complejos es decir con un mayor número de características (Viola-Jones, 2001).

Conteo de vehículos

Se realizó un programa que, utilizando las técnicas de manejo de imágenes, para la detección de objetos, usando la substracción de fondo y detección de contornos, considere el número de píxeles que cambian dentro del área de interés definida, y que corresponde a la zona por donde cruzan los vehículos de la autopista.

Las primeras pruebas se realizaron, dibujando un polígono dentro del archivo de video, para posteriormente ejecutarlo dentro de la interfaz.



Ilustración 8. Funcionalidad de conteo vehicular.

Resultados y discusión

Una vez realizado el conteo vehicular, posteriormente el desarrollo del prototipo encamina al almacenamiento de la información obtenida en una base de datos, que pueda ser consultada mediante una aplicación web, bajo el protocolo de internet, para ofrecer consultas vía remota.

De igual manera, utilizar las imágenes de video para entrenar una red neuronal para la clasificación de los vehículos.

Se puede mejorar la clasificación de los vehículos para otras categorías como autobuses, motos y camiones entrenando al clasificador usando la clase CascadeClassifier de OpenCV.

Selección de pruebas estadísticas

Las pruebas se realizaron durante un periodo de ocho horas, seleccionando el carril que tiene la dirección o sentido de tránsito Gtz-Zamora – Nautla, para la prueba de video en directo desde una cámara IP *Internet Protocol*, el análisis de las pruebas se realizó en tres días distintos, esto con el objetivo de probar en distintas condiciones de luz, el momento 1 (**M1**) se tomó la muestra en el horario de 8 a 9 hrs el día 23 de mayo del 2021, el momento 2 (**M2**) de 13 a 14 hrs del día 04 de junio 2021, y el tercer (**M3**) momento de 18 a 19 hrs el día 07 de junio.

Análisis del conteo vehicular.

Se realizó el aforo de manera visomanual en los videos para realizar la comparativa contra el conteo realizado de manera automática por la aplicación de reconocimiento de imágenes. Tomando como referencia las siguientes consideraciones, el resumen del análisis se muestra en la Tabla 2:

Verdadero Positivo: son los casos en que el objeto detectado es un vehículo real y la aplicación si lo contó correctamente.

Verdaderos Negativos: son los casos en que el objeto detectado no es un vehículo real o válido y la aplicación no lo consideró en el conteo.

Falso Positivo: son los casos en que el objeto detectado no es un vehículo y la aplicación si lo consideró en el conteo.

Falso Negativo: son los casos en que el objeto si es un vehículo real y la aplicación no lo consideró en el conteo.

Tabla 1. Aforo vehicular

Tipo de análisis de video	Resultado	M1	M2	M3
Manual	Vehículo	32	30	27
Manual	No Vehículo	3	3	6
Automático	Verdaderos positivos	24	20	22
Automático	Verdaderos negativos	0	3	1
Automático	Falsos positivos	0	7	0
Automático	Falsos negativos	8	10	9

Análisis de la clasificación vehicular

Verdadero Positivo: son los casos que pertenecen a la clase auto y la aplicación los detectó y clasificó como auto.

Verdaderos Negativos: son los casos que no pertenecen a la clase y el clasificador definió que no pertenecen a esa clase.

Falso Positivo: son los casos que no pertenecen a la clase, pero el clasificador los definió en esa clase.

Falso Negativo: son los casos que sí pertenecen a la clase y el clasificador no los definió en esa clase.

Tabla 2. Clasificación vehicular

Tipo de análisis de video	Resultado	1	2	3
Manual	Auto	21	20	24
Manual	No auto	10	11	4
Automático	Verdaderos positivos	21	15	20
Automático	Verdaderos negativos	10	7	6
Automático	Falsos positivos	5	10	3
Automático	Falsos negativos	0	5	5

Tabla 3. Porcentaje de error y de efectividad del sistema en el conteo vehicular.

Análisis de video	M1	M2	M3
Manual	32	30	27
Automático	24	20	22
Porcentaje de error	25	66.67	18.52
Porcentaje de efectividad	75	33.33	81.48

Tabla 4. Porcentaje de error y efectividad del sistema en la clasificación de autos.

Análisis de video	M1	M2	M3
Manual	21	20	24
Automático	21	15	20
Porcentaje de error	0	25	16.67
Porcentaje de efectividad	100	75	83.33

Considerando los valores de la Tabla 5, se obtiene el porcentaje de error en el conteo obtenido por la aplicación con respecto al conteo del aforo visomanual, realizado en el video, el cual consiste en el conteo visual por una persona.

A_{vm} = Aforo vehicular visomanual

A_{va} = Aforo vehicular automático

$$\% \text{ error} = \frac{A_{vm} - A_{va}}{A_{vm}} * 100$$

Tabla 5. Porcentaje de error y efectividad del software.

Análisis de video	M1	M2	M3
Manual	32	30	27
Automático	24	20	22
Porcentaje de error	25	66.67	18.52
Porcentaje de efectividad	75	33.33	81.48

En la Tabla 6, se observa el porcentaje de efectividad, la propuesta al momento aún no cumple con los índices de desempeño que debe tener un sistema aforador, el porcentaje de efectividad se incrementa de acuerdo a las condiciones de luz, se observó que es necesaria el aumento de la capacidad de procesamiento en los equipos donde se implemente el software, así como la definición de la cámara IP a utilizar.

Trabajo a futuro

El uso de la aplicación para la clasificación y conteo de vehículos, puede mejorarse al utilizar la información obtenida para su posterior análisis y toma de decisiones, se pretende que la información pueda ser consultada mediante una aplicación web.

De igual manera, utilizar las imágenes de video para entrenar una red neuronal para la clasificación de los vehículos, se puede mejorar la clasificación de los vehículos para otras categorías como autobuses, motos y camiones entrenando al clasificador usando la clase CascadeClassifier de OpenCV.

Conclusiones

Se puede concluir que es posible el uso de visión artificial para el conteo y clasificación de vehículos; se observó también que para el conteo de vehículos utilizando la técnica de substracción de fondo y detección de contornos, en algunos conteos se obtuvieron lecturas falsas debido al reflejo de la luz de los faros de los vehiculos en el agua.

Se encontró también que, en la noche, la detección de contornos se complica debido a los reflejos de luz, esto puede mejorarse si se configura la cámara en modo infrarrojo, para tener visión nocturna. Es posible obtener mejores resultados si la cámara se ubica de frente y por encima del paso de los vehículos en la autopista, mejorando el ángulo de visión, en el conteo de vehículos la velocidad del video es factor importante para que el conteo se pueda realizar de manera precisa. Se observó que los vehiculos que pasaban a mayor velocidad no se contabilizaron.

El presente trabajo permite llegar a la conclusión que el uso de visión por computadora es una herramienta útil, con poca inversión en hardware, abaratando los costos de instalación y mantenimiento de un sistema de aforo vehicular.

Referencias

- [1] Aristizábal, S. G., & Caro, A. S. (2018). Desarrollo de un semáforo portátil inteligente para el control del flujo vehicular. (p. 50). Instituto Tecnológico Metropolitano.
- [2] Bas, E., Tekalp, A. M., & Salman, F. S. (2007). Automatic Vehicle Counting from Video for Traffic Flow Analysis. 2007 IEEE Intelligent Vehicles Symposium, 392–397.
- [3] Barriga, E. R. C. (2017). Aplicación práctica de la visión artificial para el reconocimiento de rostros en una imagen. 60.
- [4] Beltrán, J.C.(2014). Tecnologías inteligentes para salvar recursos energéticos. Ciudad de México ITS México.

- [5] Chan, M.J. (2006). Sistema automático de conteo y clasificación de flujo vehicular basado en secuencias de video y redes neuronales artificiales. San Nicolás de los Garza, N.L.
- [6] Enrique Urrego, Germán & Calderón, Francisco Carlos, & Forero, Alejandro & Quiroga, Julián Armando (2009). Adquisición de variables de tráfico vehicular usando visión Por computador. *Revista de Ingeniería*, (30), 7-15.
- [7] Erhan Baş, A. Murat Tekalp, Fellow, IEEE, and F. Sibel Salman Automatic Vehicle Counting from Video for Traffic Flow Analysis. College of Engineering, Koç University, 34450 Sariyer, Istanbul, Turkey ISSN: 0121-4993.
- [8] Esparza, J. E. M. (2014). Análisis de tráfico vehicular usando visión artificial en la ciudad de San Juan de Pasto. Universidad de Nariño.
- [9] Granados, A.F. & Marín H.,J.I. (2007). Detección de flujo vehicular basado en visión artificial. *Scientia et Technica* ISSN 0122-1701, Vol. 3, No. 35, 3(35), 163-168. Recuperado de <https://dialnet.unirioja.es/servlet/articulo?codigo=4803620>
- [10] Shokravi, H., Shokravi, H., Bakhary, N., Heidarrezaei, M., Rahimian Kolor, S. S., & Petru, M. (2020). *A Review on Vehicle Classification and Potential Use of Smart Vehicle-Assisted Techniques*. *Sensors*, 20(11), 3274.
- [11] P. Viola and M. Jones, "Rapid object detection using a boosted cascade of simple features," *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. CVPR 2001, 2001, pp. I-I, doi: 10.1109/CVPR.2001.990517.