



Certificación ISO 9001:2015

Laboratorio digital de imágenes para medir flujos de vehículos en terminales intermodales de carga y vialidades. Fase I: Estudio piloto

José Alejandro Ascencio Laguna
Agustín Bustos Rosales
Jorge Artemio Acha Daza

**Publicación Técnica No. 493
Sanfandila, Qro, 2017**

SECRETARÍA DE COMUNICACIONES Y TRANSPORTES
INSTITUTO MEXICANO DEL TRANSPORTE

Laboratorio digital de imágenes para medir flujos de vehículos en terminales intermodales de carga y vialidades. Fase I: Estudio piloto

Publicación Técnica No. 493
Sanfandila, Qro, 2017

Esta investigación fue realizada en la Coordinación de Integración del Transporte del Instituto Mexicano del Transporte, por el M. José Alejandro Ascencio Laguna, el Dr. Agustín Bustos Rosales y el Dr. Jorge Artemio Acha Daza.

Contenido

Resumen		iv
Abstract		vi
Resumen Ejecutivo		viii
Introducción		1
Capítulo 1.	Generalidades	3
Capítulo 2.	Arquitectura	7
Capítulo 3.	Resultados	19
Capítulo 4.	Conclusiones	23
Bibliografía		25

Resumen

Dada la demanda de infraestructura de transporte y de servicios de esta, en cuanto a espacios públicos y sistemas de control, resulta obvio que la Ingeniería de Tránsito juega un gran papel en el contexto, al buscar disminuir los aspectos negativos que son propiciados por las condiciones actuales del servicio de transporte; tales como, congestión, accidentes e influencias negativas en el ambiente.

El presente estudio se concentra en el diseñado y codificación de un conjunto de algoritmos para la detección, el seguimiento y la clasificación de vehículos, de manera automática y en tiempo real; esto con el objetivo de conseguir información de tráfico; y con ello dar soporte a los procesos de obtención del volumen de tránsito, identificación de patrones, tasas de llegada en el autotransporte y sus tendencias, análisis de la demanda, tiempos de espera, análisis de capacidad y algunos otros más. Cabe mencionar que dicho desarrollo pretende establecer las bases necesarias para convertirse en un laboratorio nacional, con gran número de nodos en las carreteras y terminales intermodales más importantes en país, y generar información valiosa para dar soporte a la toma de decisiones. Las organizaciones gubernamentales serían los principales consumidores de dicho recurso que será compartido de manera remota y en tiempo real.

Abstract

Given the demand of transport infrastructure and services of the same in terms of public spaces and control systems, it's obvious that transit engineering play a great role in the context, Seeking to reduce the negative aspects that are propitiated by the current conditions of the transport service, such as, congestion, accidents and negative influences on the environment.

This study focuses on the design and coding of a set of algorithms for the detection, tracking and classification of vehicles automatically and in real time, this with the aim of obtain traffic information and with that to support the processes of obtaining the traffic volume, pattern identification, arrival rate in the federal motor and it's trends, demand analysis, timeouts, capacity analysis and some others more. It should be mentioned that this development intends to establish the necessary bases to become a national laboratory with a large number of nodes on the most important intermodal roads and terminals in the country, generating valuable information to support decisión-making. Government organizations will be the main consumers of this resource that will be shared remotely and real time.

Resumen ejecutivo

Esta investigación ha permitido desarrollar una arquitectura para el aforo vehicular aplicando las técnicas de Computación Acumulativa para la detección de vehículos en movimiento, y generar un fondo adecuado para la substracción de fondo, Función de Densidad de Probabilidad (FDP) de Ventanas de Parzen, para segmentar y calcular el volumen de los vehículos; análisis de varianza ANOVA, para encontrar un vehículo de un frame a otro. Obtuvimos un conjunto de muestras para validar la eficiencia de los algoritmos, con esto logramos calibrar los umbrales de substracción de fondo para no permitir gestionar pixeles que no son de interés; y eliminar el máximo ruido generado por los niveles de luminosidad y el sensor de video, anchos de ventana en la FDP para una segmentación de vehículos adecuada y su clasificación, nivel de significancia en el análisis de muestras para el correcto seguimiento de objetos en movimiento.

Los resultados obtenidos pueden ser mejorados, pues al incrementar el número de vehículos en escena se alcanzan niveles de error del 54%; los algoritmos evaluados por separado han dado buenos resultados, puesto que llegan a niveles eficiencia del 95%. Los altos niveles de error en la evaluación de la arquitectura se deben a la posición del sensor de video (pues hay objetos que obstruyen la visión del sensor), a los objetos que provocan falsos positivos en los algoritmos (específicamente los vitrales donde se reflejan los vehículos) y a los objetos ocluidos cuando entran y salen fusionados en escena sin separarse en algún momento para que el sistema de control propuesto por esta arquitectura logre discriminarlos.

Proponemos como trabajo futuro desarrollar una interfaz gráfica para dibujar un área de interés por procesar, y de esta manera eliminar los falsos positivos generados por elementos del entorno que figuren vehículos en movimiento, tales como los vitrales; entrenar una Red Neuronal Artificial para la detección de objetos fusionados; donde puedan ser discriminados con base en la dirección, tamaño de carril y correspondencia de color; además de la generación de una metodología para la correcta instalación de sensores de video (laboratorio digital de imágenes para medir flujos de vehículos en terminales intermodales de carga y vialidades Fase II), esto con el objetivo de evitar objetos que minimicen la eficiencia de los algoritmos y buscar la posición adecuada para aminorar las fusiones entre vehículos.

Introducción

Los sistemas inteligentes o nuevas tecnologías de transporte tienen como principal objetivo dar soporte a la creación de caminos, vehículos, usuarios, y aplicaciones computarizadas “más inteligentes”; y, por consiguiente, que se mejore la operación y la seguridad de los sistemas de transporte.

Los estudios más importantes de dicha línea de investigación se concentran particularmente en la implementación de *Intelligence Transport System* (ITS), evaluación de nuevas tecnologías y la obtención de información en tiempo real, de los sistemas de transporte.

Según Cal y Mayor (2007), “En el acuerdo que no se puede crecer en oferta de infraestructura y de servicios a la misma tasa de la demanda de espacio público y de sistemas de control, es obvio que se genera un rezago que propicia condiciones adversas para la sociedad, al traducirse en congestión, en accidentes y en influencia negativa al ambiente, que de manera acelerada contribuyen al deterioro de la calidad de la vida de las personas. La ingeniería de tránsito juega un papel importante dentro de este contexto, al ser una rama que busca hacer estos desplazamientos de manera segura, fluida y con el menor impacto a la sociedad”.

Según Xercavins et al. (2005), “El enorme desarrollo de las comunicaciones inmediatas y globales y de los sistemas de transporte ha sido, es y será factor determinante y esencial de la globalización. Tanto en el caso de las tecnologías del transporte, que permite la movilidad física de mercancías y personas, como en el caso de las tecnologías de la información y la comunicación, que permiten la gestión y movilidad de datos, se dispone de mecanismos que sin duda facilitan las relaciones entre distintas partes del mundo. Por esta movilidad que facilitan en grado sumo han permitido que las actividades económicas y sociales se puedan realizar a escala global”.

Con lo anterior y siendo uno de los objetivos del Plan Nacional de Desarrollo (PND) 2013-2018 de la SCT, específicamente el **Objetivo 6**: “Desarrollar integralmente y largo plazo al sector con la creación y adaptación de tecnología y la generación de capacidades nacionales”; este proyecto pretende contribuir con la generación de nueva tecnología, al desarrollar un sistema computacional que dé soporte a la ingeniería de tránsito; con la automatización de los procesos de aforo vehicular, volumen de tránsito y análisis estadístico.

Por otra parte, y como tema de gran interés, cabe mencionar que dicha propuesta también busca generar mediciones que arrojen información clara y automática que permita identificar patrones o tasas de llegada del autotransporte en los puertos y

centros de distribución. Según la Administración Portuaria Integral de Veracruz (2011), los aforos vehiculares en puertos no sólo permiten identificar tendencias; sino también son insumo para el análisis de la demanda, tiempos de espera, análisis de capacidad, y muchos otros estudios más.

1 Generalidades

1.1 La visión del Laboratorio Digital de Imágenes para medir flujos de vehículos en terminales intermodales de carga y vialidades

Debido a que el sistema computacional propuesto requiere de demasiados recursos materiales y humanos, lo hemos planteado en fases; de tal manera que el logro de los objetivos generales dependan del éxito de cada una de las etapas anteriores, el orden propuesto resulta significativo. A continuación el mapa de dichas fases:

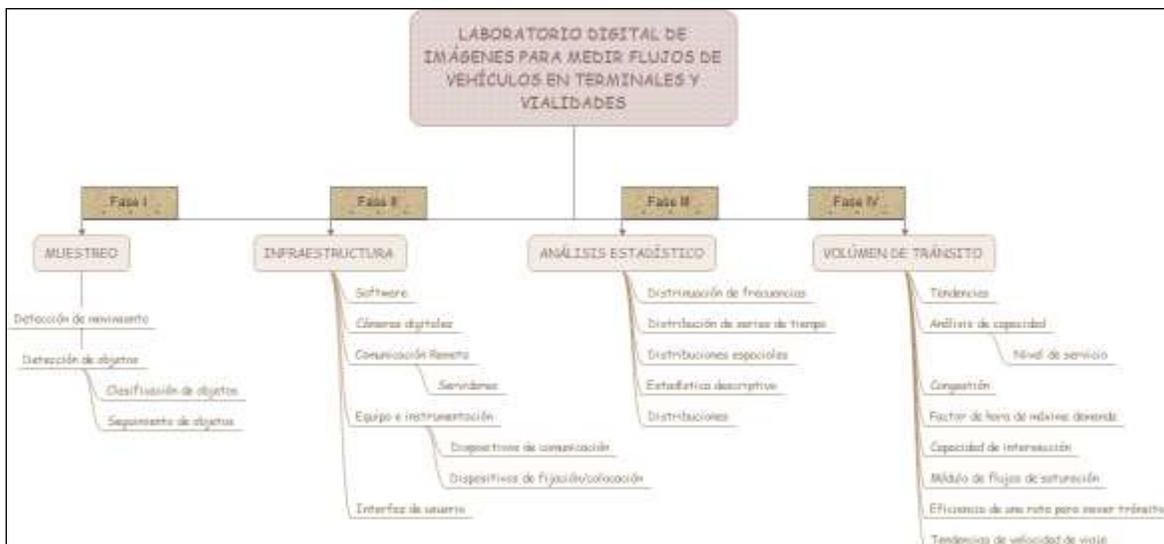


Figura 1.1.1 Mapa de Fases del Laboratorio Digital de Imágenes para medir flujos de vehículos en terminales y vialidades.

Como podemos ver en la figura 1.1, tenemos cuatro fases, el éxito de la siguiente depende de la anterior. El principal objetivo de cada fase es:

Fase 1. Generar el conjunto de algoritmos para el aforo vehicular automático.

Fase 2. Establecer, diseñar e implementar la infraestructura física para procesar los algoritmos de manera remota; los procedimientos y políticas para agregar una nueva terminal; además de los accesos para consumir la información con otras plataformas y las interfaces de consulta.

Fase 3. Producir los algoritmos y las interfaces para la generación del análisis estadístico.

Fase 4. Generar los algoritmos e interfaces para la elaboración del análisis de volumen de tránsito.

Es importante dejar en claro que el **Laboratorio Digital de Imágenes para medir flujos de vehículos en terminales intermodales de carga y vialidades** tiene la visión de incrementar al máximo el número de nodos; busca no sólo obtener las métricas antes mencionadas y compartirlas con las organizaciones gubernamentales pertinentes de manera remota y en tiempo real, sino también para incrementar sus funcionalidades y capacidades. A continuación, una imagen representativa de la visión de la propuesta:



Figura 1.1.2 Visión del Laboratorio Digital de Imágenes para medir flujos de vehículos en terminales y vialidades.

En la figura 1.1.2 podemos observar una visión del laboratorio, donde existen varias terminales alrededor del país; dichos nodos transmitirán el video a través de internet, de tal manera que la infraestructura del IMT (Fase II) pueda procesarlo a través de los algoritmos desarrollados (Fase I) y generar como resultado el muestreo vehicular (Fase I), un análisis estadístico (Fase III) y un análisis de volumen de tránsito (Fase IV). Dichos resultados estarán disponibles a través de servicios web, para que los interesados con privilegios de autorización puedan acceder a los datos de manera remota y en tiempo real.

1.2 Objetivos

1.2.1 Objetivo general

Desarrollar una aplicación para el aforo vehicular automático con base en muestras de video en terminales intermodales de carga, puertos, centros de distribución, plataformas logísticas y vialidades.

1.2.2 Objetivos específicos

Diseñar el conjunto de algoritmos de detección, seguimiento y clasificación de vehículos.

Codificar el conjunto de algoritmos.

Realizar un experimento piloto para calibrar los algoritmos, y hacer las pruebas de sistema.

Realizar las acciones mantenimiento al conjunto de algoritmos.

1.3 Alcances

El estudio consistirá en el desarrollo de los algoritmos de funcionalidad en tiempo real: detección de objetos en movimiento, segmentación, clasificación y seguimiento. También realizaremos la calibración, las pruebas y el mantenimiento de los algoritmos desarrollados.

1.4 Metodología

La secuencia metodológica por seguir es la siguiente:

1. Elemento de estudio.

Obtención de las muestras de video.

2. Análisis.

Análisis de las técnicas ya desarrolladas para la detección, segmentación, clasificación y seguimiento de objetos en movimiento; además de la identificación de los lenguajes de programación y Frameworks por utilizar.

3. Diseño.

Diseño de algoritmos de detección, segmentación, clasificación y seguimiento de vehículos.

4. Codificación.

Programación de los algoritmos diseñados en la etapa anterior.

5. Pruebas.

Realizaremos pruebas unitarias y pruebas de sistemas, además de calibrar los umbrales del procesamiento digital de imágenes.

6. Mantenimiento.

Corregir y mejorar los objetos probados.

1.5 Productos por obtener

Un conjunto de algoritmos calibrados y probados para el aforo vehicular.

La evaluación de la eficiencia de los algoritmos de aforo vehicular.

Las bases para continuar con la Fase II de la visión del laboratorio digital de imágenes para medir flujos de vehículos en terminales intermodales de carga y vialidades, expresada en la figura 1.1.1.

2 Arquitectura

En este capítulo presentamos una descripción del modelo de solución, procesos y técnicas para la obtención del aforo vehicular automático.

2.1 Modelo de solución

En la siguiente figura aparece el modelo general de la propuesta de solución:

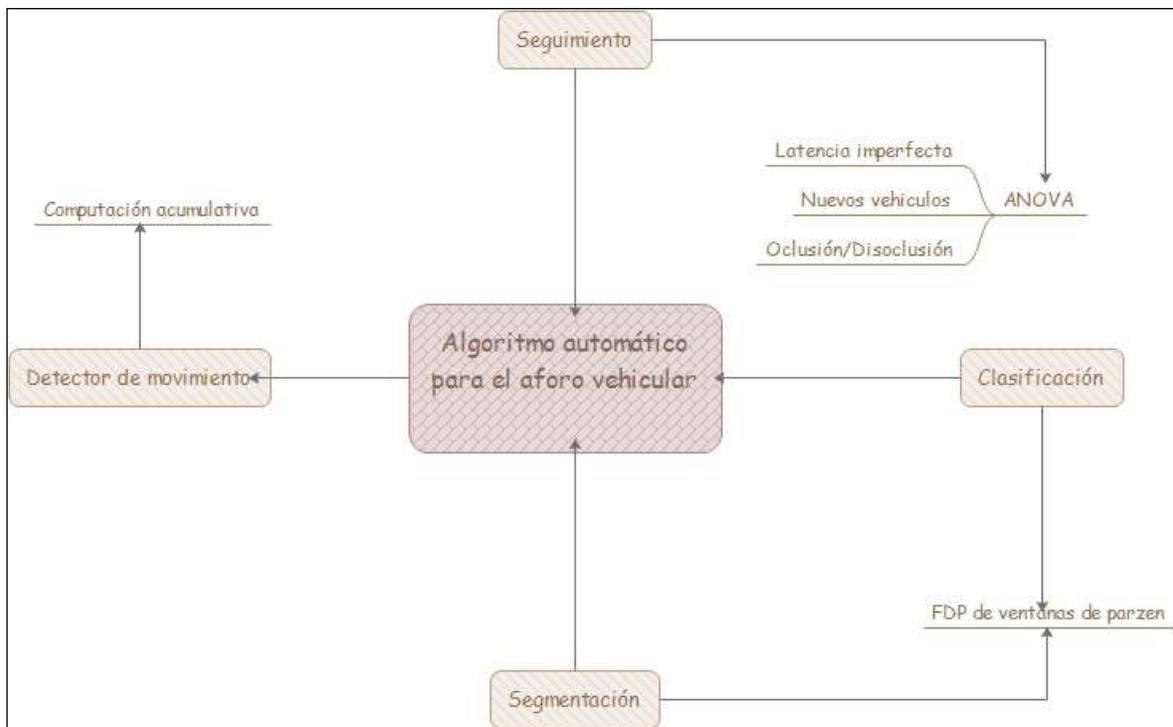


Figura 2.1 Arquitectura del modelo de solución.

En la figura 2.1 podemos observar los principales procesos y técnicas de solución; el detector de movimiento ha sido construido a través de la Computación Acumulativa, el Seguimiento y la Clasificación con la Función de Densidad de Probabilidad de Ventanas de Parzen, y por último el Seguimiento con un análisis de varianza ANOVA, el cual da pauta a las técnicas de Latencia imperfecta, Nuevos vehículos y Oclusión/Disocusión. En los siguientes apartados desarrollaremos la descripción de cada uno de estos elementos.

2.1.1 Detector de movimiento

Ferraz y Lameda (2008) demuestran que la computación acumulativa permite generar un caudal adecuado para el proceso de sustracción de fondo, esto con el objetivo de que el sistema logre segmentar los objetos en movimiento (vehículos). Esta técnica supera los problemas de falsos movimientos detectados por los cambios de iluminación en el entorno; movimiento de objetos que no son de interés, y las sombras.

A continuación, el modelo propuesto por Ferraz y Lameda (2008) para generar fondos adecuados:

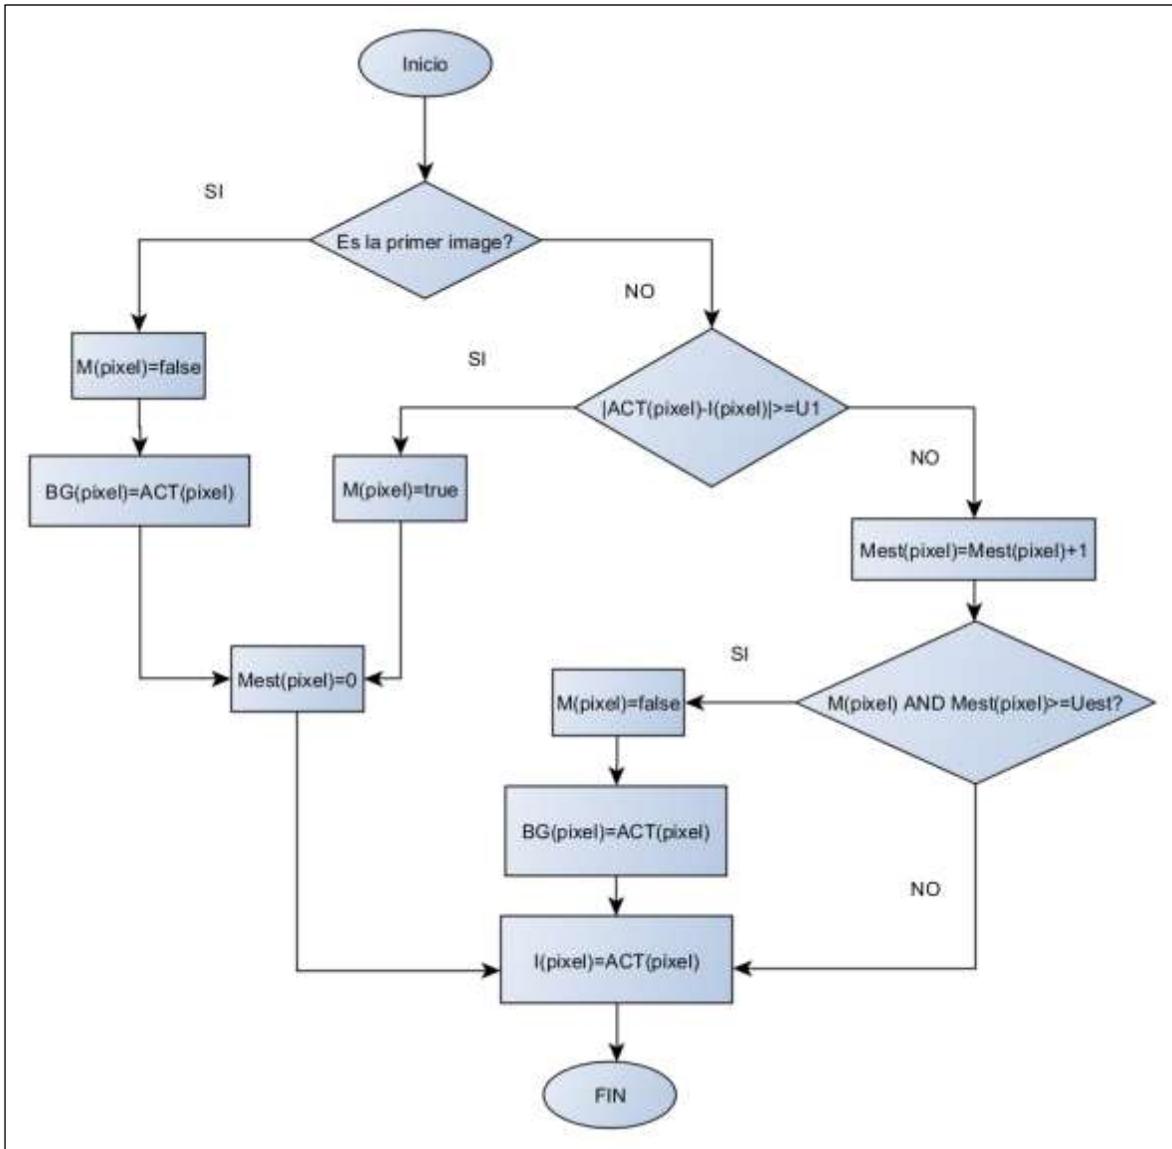


Figura 2.1.1 Modelo Computación Acumulativa.

La figura 2.1.1 muestra el diagrama de flujo del algoritmo empleado para cada píxel de la imagen, las variables expuestas indican lo siguiente:

- M***, Representa la imagen de movimiento.
- BG***, Representa la imagen de fondo.
- Mest***, Representa la imagen de estabilidad.
- ACT***, Representa la imagen actual.
- I***, Representa la imagen anterior.
- U1***, Representa al umbral de substracción de fondo.
- Uest***, Representa al umbral de estabilidad.

Podemos observar en la figura 2.1.1 que, si es la primera imagen, se determina que no hay movimiento alguno y se genera el primer fondo con los valores de la imagen actual; de lo contrario realizamos una resta de valor absoluto entre la imagen actual y la anterior para determinar -con base en el umbral de substracción- si hubo movimiento; en caso de no detectarlo, la matriz de estabilidad incrementa su valor; para que al ser superado o igualado a un umbral de estabilidad, dichos pixeles de la imagen actual formen parte del nuevo fondo.

En pocas palabras, con este algoritmo podemos obtener aquellos pixeles que se mantienen estáticos, para tomarlos como el fondo; con esto, al restar la imagen actual y el fondo, conseguimos solo los objetos de interés (los vehículos en movimiento). Es importante mencionar que si un automóvil se estaciona en escena, formará parte del fondo hasta que vuelva a moverse.

2.1.2 Segmentación

El propósito de la segmentación es obtener cada uno de los objetivos de manera independiente, gestionar su ubicación y sus características de interés; para dicho propósito, utilizamos la técnica FDP de Ventanas de Parzen, la cual consiste en el cálculo de la probabilidad de pertenencia entre las muestras y una región definida por un hipercubo con núcleo; por lo tanto, el número de muestras que caen dentro de dicha región estima los picos del diagrama de densidad.

A continuación, un ejemplo del resultado del procesamiento de un FDP de Ventanas de Parzen:

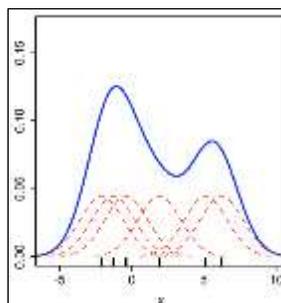


Figura 2.1.2.1 Función de densidad.

Como observamos en la figura 2.1.2.1, el procesamiento de Ventanas de Parzen coloca el núcleo de un hipercubo (ventana) en cada una de las muestras; entre más cercanas estén, el pico del gráfico incrementa su altura; el número de muestras que formarán parte de cada pico depende del ancho de ventana h y su forma de la función de núcleo k .

La FDP en este estudio es una adaptación del modelo de Wang et al. (2007), donde se calcula una función en dos dimensiones, un tamaño de ventana para cada conjunto y las muestras que formaran parte del hipercubo depende del nivel de color:

$$p(x, y) = \frac{1}{2\pi N} \sum_{i=1}^L \sum_{j=1}^{C_i} \frac{1}{h_{c_i}^2} \exp\left(-\frac{(x-x_j)^2 + (y-y_j)^2}{2h_{c_i}^2}\right) \quad \text{Función 2.1.2.1}$$

Por otro lado, la propuesta consiste en un solo tamaño de ventana, las muestras que forman parte del hipercubo dependen de la cercanía y consideramos un píxel para el núcleo del pico; la describimos a continuación:

$$p(x, y) = \frac{1}{2\pi N} \sum_{j=1}^{M_c} \frac{1}{(2h+1)^2} \exp\left(-\frac{(x-x_j)^2 + (y-y_j)^2}{2(2h+1)^2}\right) \quad \text{Función 2.1.2.2}$$

donde,

- x , Es la coordenada renglón donde se ha posicionado el núcleo del hipercubo.
- y , Es la coordenada columna donde se ha posicionado el núcleo del hipercubo.
- x_j , Es la coordenada renglón del conjunto de muestras que quedan dentro del hipercubo.
- y_j , Es la coordenada columna del conjunto de muestras que quedan dentro del hipercubo.
- h , Es el tamaño del hipercubo.
- M_c , Es el conjunto de posiciones (x_j, y_j) de las muestras que quedan dentro del hipercubo.

Con la función 2.1.2.2 buscamos generar picos gaussianos por cada vehículo detectado, a continuación los resultados de dicho algoritmo:

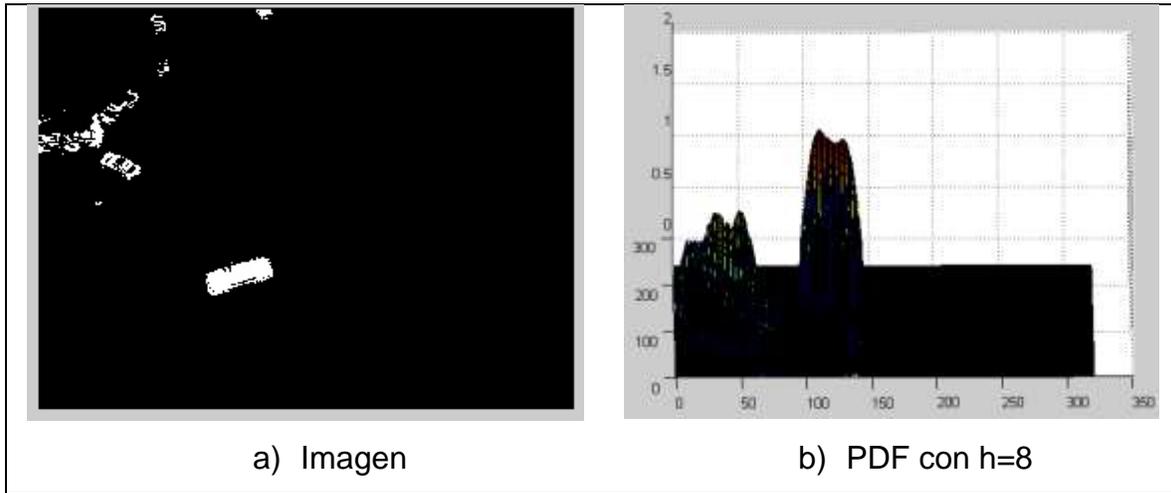


Figura 2.1.2.2 FDP de Ventanas de Parzen.

Como podemos ver en la figura 2.1.2.2, se generan dos picos para el vehículo que se encuentra en la parte inferior *a) Imagen*; esto provocaría un error; puesto que si buscáramos los máximos locales, nos encontraríamos con dos cuando solo es uno; para solventar dicho inconveniente es necesario calibrar el valor h ; entre más grande sea este, se generará menos picos, y entre más grande se generará más picos. En este caso si h fuera mucho más grande, se generaría sólo un máximo local, aunque sería multimodal; de esta manera, discriminarlo sería muy sencillo.

2.1.3 Clasificación

La clasificación vehicular dependerá de los resultados de la FDP de ventanas de Parzen y del nivel de reconocimiento deseado, en esta propuesta buscamos hacer una clasificación básica a través de la obtención de la altura de cada pico encontrado en la fase de **segmentación**; con esto decimos que entre más alto sea el pico gaussiano y más pixeles formen parte del máximo local, más grande será el vehículo. A continuación, un ejemplo de los resultados generados por el algoritmo:

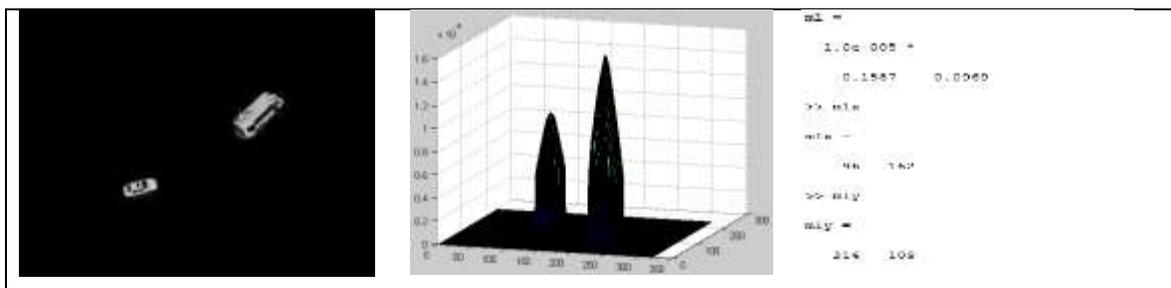


Figura 2.1.3.1 Clasificación vehicular.

La figura 2.1.3.1 es un ejemplo de los resultados obtenidos en el algoritmo de clasificación; ml es el valor de la altura de los picos encontrados, mlx es la

posición abscisa y *mly* posición ordenada. Como podemos observar, el algoritmo propuesto es una herramienta potencial para hacer una clasificación de vehículos pequeños, medianos y grandes.

2.1.4 Seguimiento

Ya que hemos segmentado los vehículos, a través de la FDP de ventanas de Parzen, debemos hacer el seguimiento de los objetos; esto se logra localizando a cada objeto de un frame a otro. Es importante tomar en cuenta los posibles cambios que pueden ocurrir en escena, que afectan los niveles de color y los valores estructurales del vehículo.

Gracias a la detección de los núcleos de los objetos de interés en escena, es posible realizar un análisis de varianza entre los objetos más cercanos de un frame a otro; con estos logramos determinar su similitud y por consiguiente su movimiento.

Según Levin et al. (2010), la técnica conocida como análisis de varianza y reconocida como ANOVA (Analysis of variance) permite identificar las diferencias entre más de dos medidas muestrales; con esto decimos que a través de esta técnica es posible inferir si las muestras por analizar tienen la misma medida. Usando ANOVA hemos logrado determinar cuánto se parece un vehículo en el tiempo t con los demás más cercanos a él, en el tiempo $t + 1$; de tal modo que cada vehículo es localizado en cada instante de la secuencia de video.

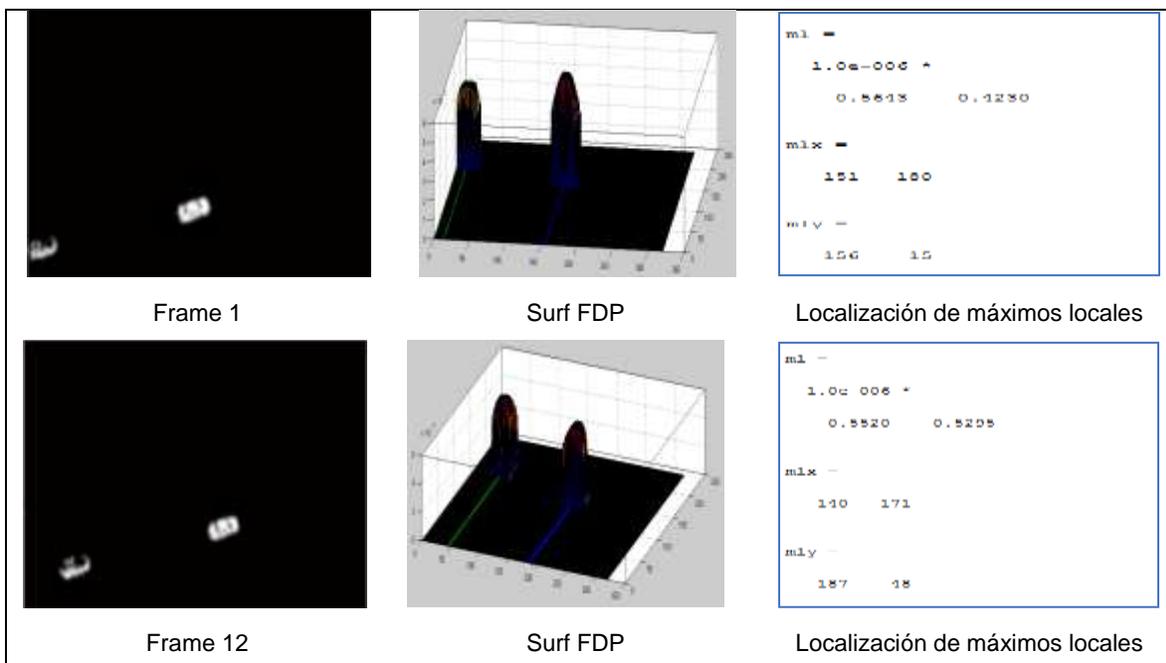


Figura 2.1.4 ANOVA para el proceso de detección de similitud.

En la figura 2.1.4.1 (ANOVA para el proceso de detección de similitud) podemos observar dos frames con sus respectivas coordenadas y altura de pico; lo

importante de esta figura es que a manera de prueba hayamos identificado los vehículos manualmente, esto a través de un color verde para el primer vehículo y azul para el segundo; esto quiere decir que antes de ejecutar el algoritmo de similitud, sabemos la localización de los vehículos en el frame 1 y frame 12; este experimento ayudará a determinar la eficiencia de la técnica utilizada. A continuación, en la tabla 2.1.4 (Prueba del algoritmo ANOVA), los resultados obtenidos:

Tabla 2.1.4 Prueba del algoritmo ANOVA

Prueba	Hipótesis	ANOVA ($\alpha = 0.02$) y punto crítico de 6.6744
		Función de prueba
1	Frame 1 vs Frame 12	$F = 5.6010$
2	Frame 1 vs Frame 12	$F = 0.0422$
3	Frame 1 vs Frame 12	$F = 29.2449$
4	Frame 1 vs Frame 12	$F = 2.2588e^{+003}$
Definición de la prueba:		
$H_0: \mu_1 = \mu_2$		
$H_1: \mu_1 \neq \mu_2$		
Lo cual quiere decir que cuando la función de prueba es menor al punto crítico, se asume que un vehículo es el mismo en el frame 1 y el frame 12		

Fuente: Prueba realizada por el IMT

El modelo para desarrollar el algoritmo de similitud es la codificación del propio modelo ANOVA, presentado a continuación:

- Función de prueba.

$$F = MSTR/MSE$$

- Cuadrado medio entre los grupos

$$MSTR = SST/(K - 1)$$

- Cuadrado medio en los grupos

$$MSE = SSE/(N - K)$$

- Suma de cuadrados entre los grupos

$$SST = \left(\sum_{c=1}^K \left(\frac{t_c^2}{n_c} \right) \right) - \left[\left(\sum_{i=1}^{n_c} X_i \right)^2 / \left(\sum_{c=1}^K n_c \right) \right]$$

donde

K ,	Es el número de muestras por evaluar
t_c ,	Es la suma de los valores de cada muestra
n_c ,	Es el número de elementos de cada muestra
X_i ,	Es el valor de cada elemento de muestra

- Suma de cuadrados en los grupos

$$SSE = \left(\sum_{i=1}^{n_c} X_i^2 \right) - \left(\sum_{c=1}^K \left(\frac{t_c^2}{n_c} \right) \right)$$

donde

K ,	Es el número de muestras por evaluar
t_c ,	Es la suma de los elementos de cada muestra
n_c ,	Es el número de elementos de cada muestra
X_i ,	Es el valor de cada elemento de muestra

- Grados de libertad entre los grupos

$$K - 1$$

donde

K ,	Es el número de muestras por evaluar
-------	--------------------------------------

- Grados de libertad en los grupos

$$N - K$$

donde

K ,	Es el número de muestras por evaluar.
N ,	Es la suma de todos los n_c .

2.1.4.1 Errores en el proceso de seguimiento

A continuación presentamos los eventos más significativos que perjudican la secuencia del procesos de seguimiento:

- **Oclusión/disocclusión.** La oclusión es cuando un objeto se fusiona con otro, y la disocclusión es el evento contrario; cuando un objeto se separa de otro. El problema radica que se pierde al vehículo que se está siguiendo, ya sea porque se encimó con otro o porque se separó en algún instante de la secuencia.

- **El objeto deja de moverse por algunos instantes.** Cuando un vehículo se detiene, el sistema deja de detectarlo (computación acumulativa), quiere decir que desaparece de la escena hasta que este vuelva a moverse; por consecuente vuelve a contabilizarse y genera falsos positivos.
- **El objeto es estadísticamente similar a otro.** Existe la posibilidad de que los colores y valores estructurales de un vehículo sean muy parecidos, el análisis ANOVA concluirá que son el mismo objeto; por consecuente se perdería la secuencia de seguimiento de dichos vehículos.

Para solventar los errores expresados anteriormente, proponemos los siguientes algoritmos:

- **Determinación de las fronteras.** Es la detección a priori de la localización de las áreas de entrada y salida de vehículos, su principal objetivo es determinar en qué momento un objeto en movimiento aparece por primera vez y cuándo sale de escena.
- **Determinación de la distancia entre máximos locales.** Es la generación de un matriz cuadrática de distancias entre vehículos que permite discriminar o evitar comparar la similitud entre objetos que se encuentran muy alejados entre el instante t y $t + 1$; quiere decir que si dos elementos están muy alejados se da por hecho que no pueden ser el mismo vehículo, aun cuando sus varianzas sean muy parecidas.
- **Determinación del desplazamiento.** Permite conocer la dirección que van tomando los vehículos, en carreteras de un solo sentido sería muy complicado que la dirección cambiara bruscamente; sin embargo, en cambios de carril y cuando los vehículos están muy cercanos, este elemento será de suma importancia para detectar fusiones.
- **Determinación de la latencia.** Es el factor de continuidad de un vehículo en los cuadros consecutivos, La latencia junto con la información de desplazamiento y la localización de las fronteras son los factores que permitirán determinar la presencia de oclusiones/disocclusiones. Si en determinado instante en dos o más objetos el coeficiente de latencia disminuye considerablemente y su dirección es muy parecida, es muy posible que haya ocurrido una oclusión; por otro lado, si la latencia disminuye y aparece un nuevo objeto lejos de las fronteras, es muy posible que haya ocurrido una disocclusión.

A pesar de que ya tenemos identificados los elementos que ayudan a solventar los errores detectados, es necesario definir las siguientes reglas.

- Si el objeto no reconocido por en análisis de similitud está lejos de las fronteras y realizando otro análisis con los objetos de baja latencia, se cumple la hipótesis nula (se encontró similitud); significa que hubo un cambio drástico de luminosidad en la escena.
- Si el objeto no reconocido por el análisis similitud está cerca de las fronteras de entrada, significa que es un vehículo nuevo.

- Si las coordenadas del núcleo de un objeto no reconocido por el análisis de similitud en el instante t forman parte de otro tampoco reconocido en el instante $t + 1$, significa que se fusionaron (oclusión).
- Si las coordenadas del núcleo de un objeto no reconocido por el análisis de similitud en el instante $t + 1$ forman parte de otro tampoco reconocido en el instante t , significa que dos o más objetos se han separado (disoclusión).

Con base en las reglas expresadas anteriormente, y los elementos para solventar los errores de seguimiento, codificamos los siguientes algoritmos:

- **Latencia imperfecta.** Realizamos un segundo análisis de similitud entre vehículos de hipótesis alternativa en el instante $t + 1$, y los vehículos de baja latencia; quiere decir que este algoritmo busca la similitud entre los objetos no reconocidos de manera constante, pues cabe la posibilidad de que sean reconocidos en instantes futuros. A continuación, la figura 2.1.4.1.1 presenta el algoritmo:

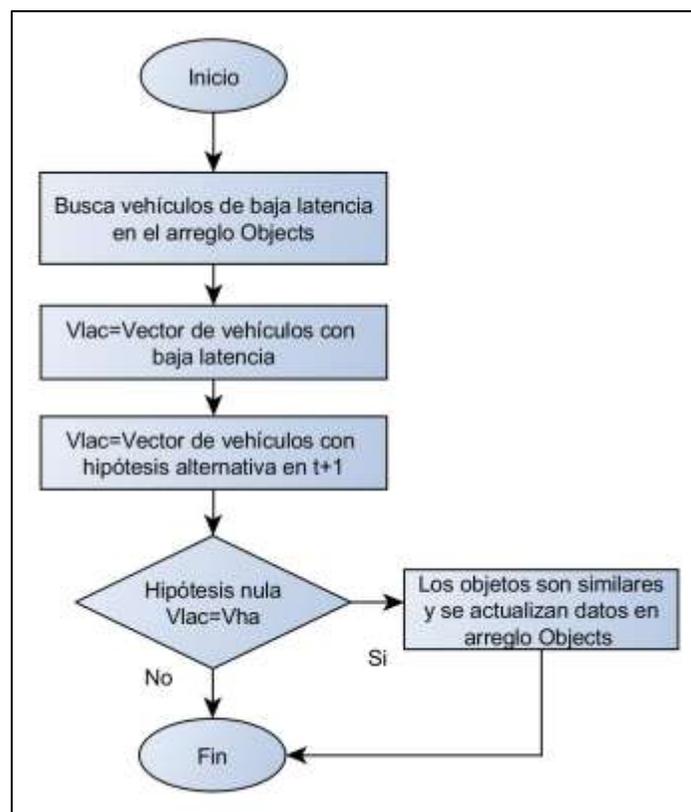


Figura 2.1.4.1.1 Latencia imperfecta.

- **Nuevos vehículos.** Calcula el nivel de cercanía entre los objetos de hipótesis alternativa y las fronteras determinadas a priori con umbral de distancia que

permite determinar si un objeto acaba de entrar a escena. A continuación, en la figura 2.1.4.1.2 presentamos el algoritmo:

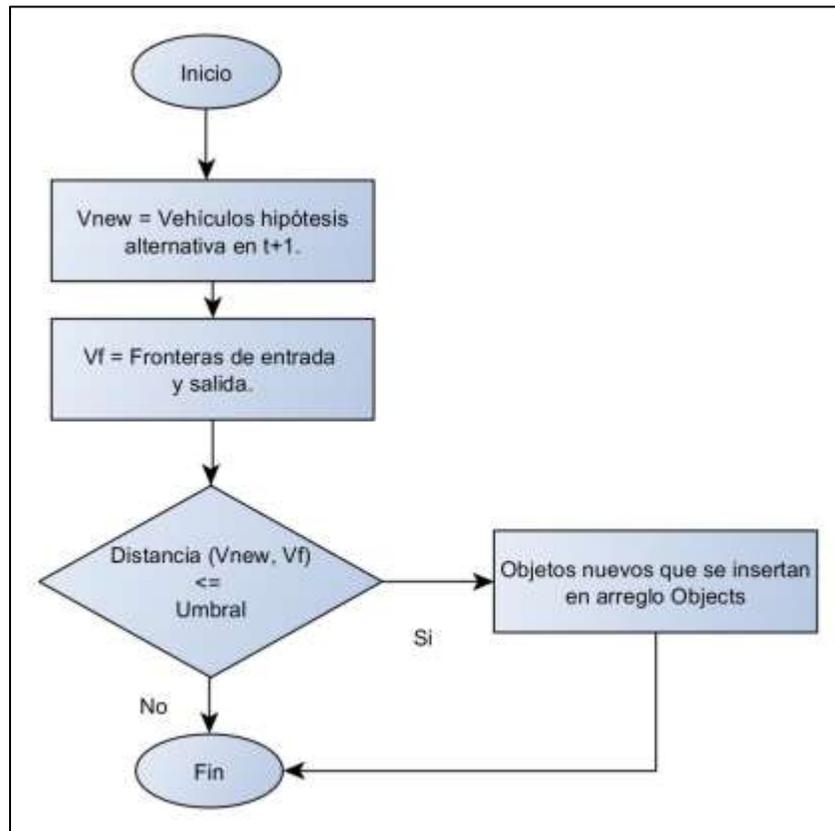


Figura 2.1.4.1.2 Vehículos nuevos.

- **Oclusión/disocclusión.** Consiste en determinar cuándo los objetos se han fusionado o separado de otros en el instante $t + 1$. A continuación, la figura 2.1.4.1.3 presenta el algoritmo:

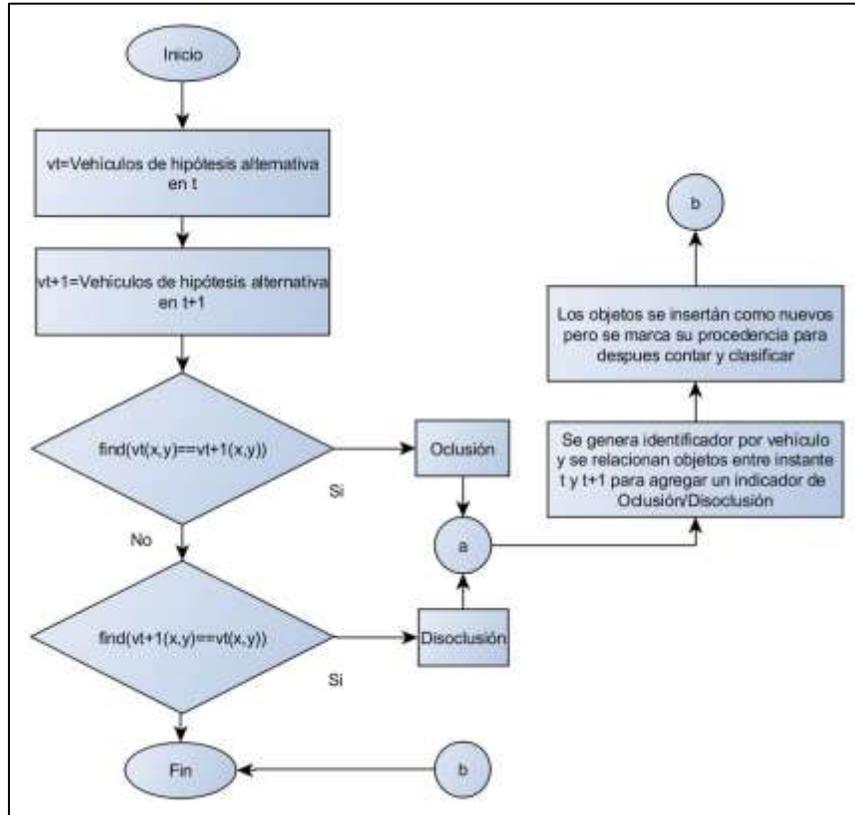


Figura 2.1.4.1.3 Oclusión/Disocclusion.

Los algoritmos presentados anteriormente trabajan en conjunto; por lo tanto, el orden de ejecución es de suma importancia, pues existe un parámetro de comunicación que permite que el siguiente proceso funcione de la manera correcta. A continuación, en la figura 2.1.4.1.4, aparece el flujo de procesos:

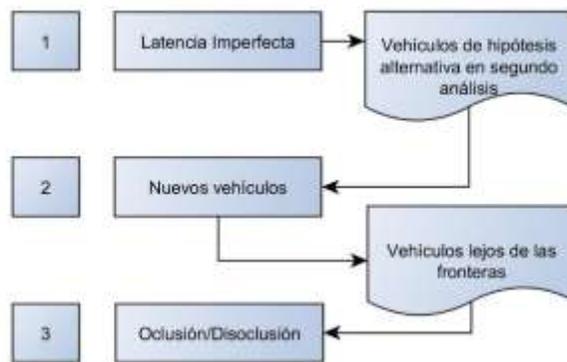


Figura 2.1.4.1.4 Flujo de ejecución

3 Resultados

En este apartado buscamos hacer la descripción de los resultados obtenidos, los más importantes, así como también expresar los defectos y debilidades; en el caso de las oportunidades de mejora, los reservaremos para el apartado de conclusiones.

Ya que las imágenes son procesadas a escala de grises para mejorar el rendimiento en cuanto a tiempo de procesamiento, hemos detectado el riesgo de pasar por alto aquellos vehículos de baja reflectancia; concluimos que esto sucede debido a que dichos objetos tienen un nivel de luminosidad muy parecido al de la carretera. La solución propuesta para reducir el nivel de error en este contexto es obtener un mínimo valor de umbral en el proceso de substracción de fondo; para esto hemos definido los colores de vehículo que generan más problemas, el negro y el gris, y hemos gestionado para obtener sus desviaciones estándar y calibrar dicho umbral; a continuación, la tabla 3.1 representa sus valores:

Tabla 3.1 Nivel de dispersión en objetos con colores problemáticos

Color	StdDev	Mean	Min	Max	Mode	MinVal
Negro	14.287	25.207	0	54	26(9)	10.92
Gris	28.141	40.585	0	112	22(11)	12.44

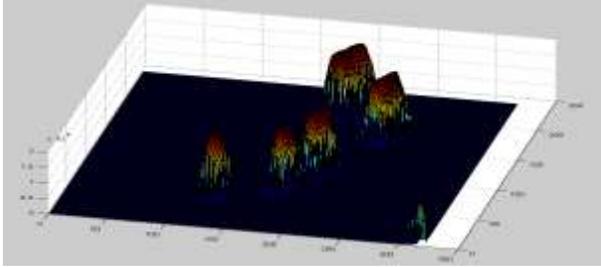
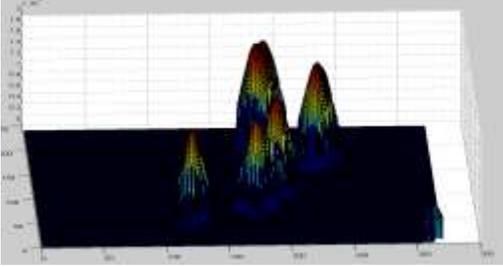
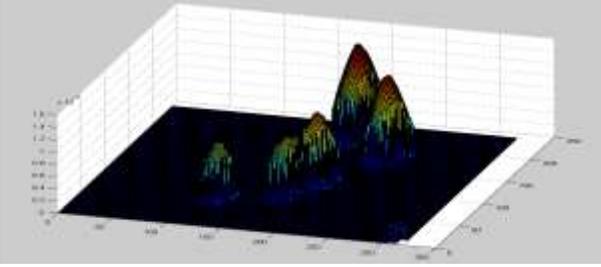
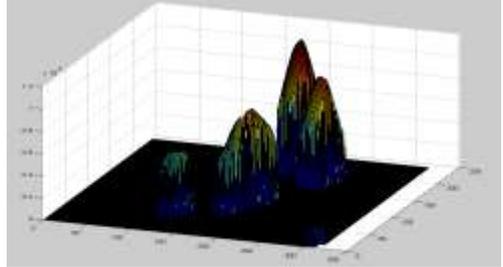
StdDev: Desviación estándar, **Mean:** Media, **Min:** Mínimo valor encontrado en la distribución, **Max:** Máximo valor encontrado en la distribución, **Mode:** Moda, **MinVal:** Mínimo valor calculado.

Fuente: Prueba realizada por el IMT

Con base en la tabla 3.1 podemos determinar que el valor de umbral más adecuado estará entre los dos mínimos valores calculados. En el caso de estudio, utilizamos un valor de umbral $U1 = 11$.

La eficiencia del proceso de segmentación depende del tamaño de ventana de Parzen h , ya que este valor delimita la cantidad de píxeles que formarán parte de cada uno de los vehículos ya segmentados. En la tabla 3.2 podemos observar que $h = 10$ es un valor de ventana óptimo, ya que los picos de cada objeto están bien identificados; por otro lado, con $h = 5$ se genera más de un pico para cada objeto y con $h = 15$ o 20 se comienzan a fusionar.

Tabla 3.2 Calibrando el tamaño de ventana.

Muestra	
	
$h = 5$	$h = 10$
	
$h = 15$	$h = 20$

Fuente: Prueba realizada por el IMT

El proceso de seguimiento depende del valor de significancia obtenido en el análisis de varianza ANOVA; en la tabla 3.3 observamos que el valor $\alpha = 0.02$ es óptimo; ya que a pesar de que en un instante de tiempo un objeto no se reconoce (H_a), sin embargo el proceso de Latencia Imperfecta logra encontrarlo en el historial de vehículos desaparecidos (H_n), así logramos la detección y seguimiento de los tres vehículos en la escena.

Tabla 3.3 En busca de un nivel de significancia óptimo

Frames	Veh	α	Ha	New	L_imp	Hn	Tv	Error
36	3	0.01	2	2	2	1	3	6%
36	3	0.02	1	1	2	1	3	3%
36	3	0.03	3	1	2	1	3	8%
36	3	0.04	3	1	2	1	3	8%
36	3	0.05	3	1	2	1	3	8%
36	3	0.06	5	2	3	2	4	14%

Frames: Total de *frames* en la secuencia de estudio, **Veh:** Total de vehículos aparecidos en la secuencia, α : Nivel de significancia para el análisis de varianza, **Ha:** Instantes donde la hipótesis alternativa se cumple, **New:** Detección de vehículos nuevos, **L_imp:** Número de veces donde el algoritmo encuentra en el historial vehículos de latencia imperfecta, **Hn:** Instantes donde la hipótesis nula se cumple, **Tv:** Total de vehículos registrados al final de la secuencia, **Error:** Nivel de error.

Fuente: Prueba realizada por el IMT

4 Conclusiones

La calibración del sistema propuesto en esta investigación debe tomar en cuenta que los cambios drásticos en el tamaño de la *Ventana de Parzen* afecta la clasificación vehicular y el proceso de segmentación. Esto significa que una ventana grande facilita la clasificación, pero incrementa la probabilidad de que existan más fusiones de objetos (oclusiones); por otro lado, una ventana pequeña disminuye la existencia de oclusiones, pero σ en la altura de los picos gaussianos es baja, evento que hará que las alturas en los picos sean muy parecidas y esto genera algunas dificultades a la hora de clasificar.

En este trabajo hemos procesado los fotogramas a escala de grises, pues buscamos optimizar el tiempo de procesamiento al máximo, ya que la transmisión de video y su procesamiento está pensado en tiempo real. En la actualidad ya hay sistemas operativos que manejan el procesamiento gráfico de manera independiente y en paralelo, un ejemplo es CUDA de NVIDIA; una mejora a futuro podría ser adecuar los algoritmos desarrollados a una infraestructura de este tipo y procesar la secuencia de video a color (RGB); esto mejoraría la fiabilidad del análisis ANOVA, pues las similitudes y diferencias entre objetos de color son muchísimo más representativas.

Para investigaciones futuras, una buena oportunidad sería hacer un análisis sobre la clasificación vehicular, a través del cálculo de la altura de los picos gaussianos; la experimentación podría ser realizada con base en la desviación estándar entre las muestras de un conjunto de vehículos de distintos tamaños; de esta manera sería posible proponer umbrales de tamaño de objetos para determinar una clasificación más robusta.

Bibliografía

Cal, R. y Mayor, R. *Ingeniería de Tránsito: Fundamentos y aplicaciones* [libro]. 8^a ed. México (2007). Alfaomega. p. VIII.

Xercavins, J., Gemma, D.C. y Sabater, A. *Desarrollo Sostenible* [libro]. 1^a ed. Universidad Politécnica de Cataluña. España (2005). pp. 101-102.

Secretaría de Comunicaciones y Transportes. *Plan Nacional de Desarrollo 2013-2018* [en línea]. Programa Sectorial de Comunicaciones y Transportes. México (2013). p. 76.

Administración Portuaria Integral de Veracruz. Centro de atención logística al transporte. México 2011 [citado noviembre 17, 2016]. Disponible en la página oficial de la Administración Portuaria de Veracruz: http://www.puertodeveracruz.com.mx/apiver/archivos/IFAI/2012/Libros_Blanco/Archivos/Anexos/Docs/GICO1207/CB%20CALT%202011.pdf.

Ferraz, A. y Lameda, C. *Extracción automática de características de vehículos en movimiento a partir de videos basada en red neuronal de Kohonen*. Ingeniería UC [en línea]. 2008, vol. 15, no. 3 [citado noviembre 17, 2016]. Disponible en la página oficial de Ingeniería UC. pp- 33-44.

Wang, S., Chung, F. & Xiong, F. *A novel Image thresholding method base don Parzen window estimate*. Pattern Recognition Society [en línea]. 2008, vol. 41 [citado noviembre 17, 2016]. Disponible en la página oficial de Pattern Recognition Society. pp. 117-129.

Leving, R. y Rubin, D. *Estadística para administración y economía* [libro]. 7^a ed. México (2010). Prentice Hall. pp. 468-475.



Km 12+000 Carretera Estatal 431 “El colorado-Galindo”
Parque Tecnológico San Fandila
Mpio. Pedro Escobedo, Querétaro, México
CP 76703
Tel +52 (442) 216 9777 ext. 2610
Fax +52 (442) 216 9671

publicaciones@imt.mx

<http://www.imt.mx/>