

Segmentación de Patentes Vehiculares Mediante Técnicas de Agrupamiento en Ambientes Externos

Juan Francisco Rojas-Henríquez
EUIIS: Área de Ingeniería en Computación e
Informática
Universidad de Tarapacá
Arica, Chile
e-mail: juanrojashenriquez@gmail.com

Diego Alberto Aracena-Pizarro
EUIIS: Área de Ingeniería en Computación e
Informática
Universidad de Tarapacá
Arica, Chile
e-mail: daracena@uta.cl

Resumen— En este trabajo se presenta un método de segmentación de patentes vehiculares mediante el empleo de técnicas de agrupamiento. Para lograr este objetivo se realizaron diferentes pruebas con clusters, comparando su desempeño y efectividad. Este método utiliza técnicas de agrupamiento para eliminar, de manera automática, los puntos espurios que pueden ser generados por las técnicas de obtención de correspondencias. Para realizar la segmentación de patentes vehiculares, el método recibe como entrada, una nube de puntos correspondientes, resultantes de un matching entre los descriptores SIFT (Scale Invariant Features Transforms) de la imagen inicial y una imagen patrón que contiene los posibles caracteres de una patente vehicular. Mediante técnicas de agrupamiento, se obtiene el cluster conformado por los puntos ubicados en la zona de la placa y además su centroide asociado. Luego se emplea la técnica de crecimiento de regiones para segmentar el área mínima que encapsula al centroide, la cual constituye la placa patente de la imagen considerada. Finalmente se pudo comprobar que la aplicación de técnicas de agrupamiento resultó ser efectiva para lograr el propósito de esta investigación.

Palabras claves: Segmentación de patentes vehiculares; técnicas de obtención de correspondencias; SIFT (Scale Invariant Features Transforms); técnicas de agrupamiento; crecimiento de regiones.

Abstract— This paper presents a method of segmentation of license plates through the use of clustering techniques. To achieve this goal were different tests with clusters, comparing its performance and effectiveness. This method uses clustering techniques to remove automatically, spurious points that can be generated by the correlation techniques. To perform segmentation of license plates, the method receives as input a cloud of points corresponding, resulting in a matching between the initial image descriptors SIFT (Scale theory Features Transforms) and an image pattern that contains the possible characters of a license plates. Through clustering techniques, gets the cluster consisting of the points located in the zone of the plate and also his associate centroid. Regions growing technique is then used to segment the minimum area that encapsulates the centroid which constitutes the patent plate of the

considered image. Finally, it was proved the technical application group resulted being effective to achieve the objective of this research.

Key words: segmentation of license plates, getting correspondence techniques; SIFT (Scale Invariant Features Transforms); clustering techniques; regions growing.

I. INTRODUCCIÓN

Dentro de los sistemas de detección y reconocimiento de placas patentes, la etapa de detección es clave, puesto que una correcta localización y segmentación de la placa, constituye el primer paso para lograr un buen reconocimiento posterior.

Debido a la importancia que tiene una buena detección y segmentación de la placa, los métodos utilizados deben ser cada vez más eficientes y robustos para enfrentar al máximo los niveles de entropía del escenario, en donde se implementará la aplicación. De esta forma es de vital importancia contar con procesos de detección invariantes a la rotación, escala, traslación y luminosidad en ambientes no preparados.

Los métodos usados en la literatura referencial para localizar la placa dentro de la imagen inicial son variados. En [1], se hace uso de operadores morfológicos, en el cual los caracteres son objetos formados por trazos colocados sobre un fondo de color opuesto. Esto permite detectarlos con la transformación morfológica “top-hat”, que se basa en borrar los caracteres de la imagen original mediante un proceso “closing” para posteriormente realizar una resta entre ambas ($close(I)-I$), obteniendo una imagen en la cual aparecerán los caracteres resaltados.

En [2], se utiliza la cuantificación de vectores (Vector quantization o VQ). Esta técnica se usa, generalmente, para la compresión de datos. Consiste en utilizar un “libro de código” predefinido, en el que cada entrada lleva asociada una probabilidad de formar parte de la placa. De esta forma se aumenta la posibilidad de localizar con precisión el área donde se encuentra la patente vehicular.

En [3], se aplica lógica difusa (Fuzzy Logic). Aquí la imagen del automóvil es particionada en rectángulos de un

tamaño aproximado al ocupado por la placa. En estos rectángulos se calcula la "membresía" de conjuntos difusos, creados a partir de reglas intuitivas como el área aproximada de localización de la placa, la brillantez del borde, etc.

En [4], se propone un método configurable de reconocimiento de placas "multi-estilo", el cual consiste en la adaptación de parámetros como: ángulo de rotación, número de líneas, tipos de caracteres y formatos de caracteres, de acuerdo a las características de las placas. Esta cualidad permite obtener el reconocimiento de placas de distintas nacionalidades. Por otro lado, en [5], el método MNS (Multimodal Neighborhood Signature), hace uso de la textura del color de la placa como una señal para su detección.

En [6] se presenta un método basado en gradientes para localizar y segmentar la placa vehicular. Inicialmente se detectan los bordes verticales de la imagen, a través del operador de derivación de Sobel. Posteriormente se calcula un umbral para clasificar la imagen gradiente en tres posibles valores (-1, 0, 1), que junto a parámetros inicialmente conocidos de la placa, como sus dimensiones, distancia entre caracteres y ancho de sus trazos, se utilizan para segmentar la placa vehicular mediante las características de la firma.

Por último, en [7], se hace uso de SIFT para el reconocimiento de placas patentes. Este método consiste en realizar un matching entre la imagen inicial y un set de imágenes de placas previamente conocidas, con el fin de encontrar aquella imagen que presente el mayor número de correspondencias, es decir la placa a la cual se está siendo referencia. De esta forma se habrá encontrado la placa patente y por consecuencia reconocido de manera directa. Aun así, el porcentaje de éxito no es satisfactorio, por lo que los autores recomiendan realizar un filtro de detección de bordes verticales sobre la imagen inicial y segmentar la patente vehicular mediante un método basado en gradientes antes de la aplicación de SIFT. Por esta razón, el problema de la detección de placas patentes mediante técnicas invariantes, sigue siendo un tema abierto a la investigación.

Este trabajo, inspirado en [7], presenta una arquitectura para detectar placas patentes, no conocidas, mediante técnicas invariantes en ambientes externos. Para lograr este cometido, se utilizó SIFT para detectar los puntos característicos y los descriptores de la imagen inicial y de una imagen patrón. Luego, se realizó un matching para obtener los puntos correspondientes entre ambas imágenes y posteriormente, como parte fundamental de este proceso, se aplicaron las técnicas de agrupamiento k-means, fuzzy c-means y mean shift, para determinar el cluster que representa a la placa vehicular. Finalmente se aplicó la técnica de crecimiento de regiones para segmentar la placa patente que deberá pasar a la etapa de reconocimiento de caracteres para finalizar el proceso.

Como trabajo a seguir, se investigarán otras técnicas de agrupamiento, con el fin de obtener nuevos resultados en cuanto a efectividad y tiempo de ejecución del método propuesto.

II. PRELIMINARES

A. Arquitectura del sistema

Este trabajo se enfoca en la primera etapa de un sistema de detección y reconocimiento de patentes vehiculares, la cual consiste en detectar y segmentar la placa que contiene los caracteres a reconocer. Esta etapa es fundamental para el sistema, puesto que sólo si se obtiene una correcta detección y segmentación de la placa, se podría llegar a alcanzar un exitoso reconocimiento posterior.

La arquitectura del sistema de segmentación de patentes vehiculares mediante técnicas de agrupamiento en ambientes externos "Fig. 1", está compuesta por 4 etapas principales:

- Detección de puntos característicos.
- Matching.
- Agrupamiento (Clustering).
- Crecimiento de regiones.

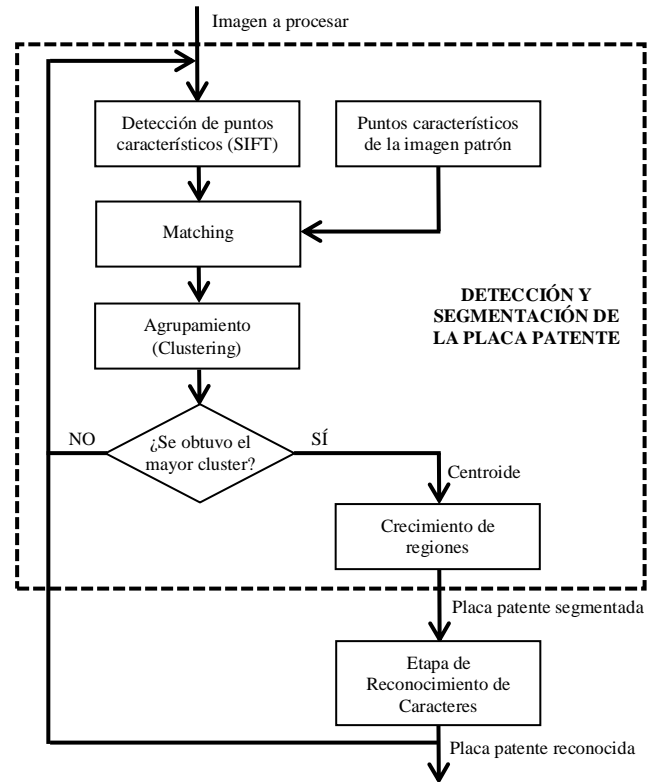


Figura 1. Arquitectura del sistema de segmentación de patentes vehiculares mediante técnicas de agrupamiento en ambientes externos.

B. Metodología

1) *Detección*: En esta primera etapa se realiza la *detección de puntos característicos y descriptores* de la imagen inicial y el *matching* para obtener los puntos correspondientes entre dicha imagen y una imagen patrón que contiene los posibles caracteres de una patente vehicular.

a) *Detección de puntos característicos y descriptores:*

Uno de los métodos de detección de puntos invariantes ampliamente utilizado en la literatura, es SIFT (Scale Invariant Features Transforms) [8]. Este detector transforma los datos de la imagen en coordenadas invariantes a la escala, rotación y en cierta medida al cambio de iluminación. Cada uno de los datos extraídos se considera una característica de la imagen y se describe mediante su posición, escala, orientación y su vector descriptivo (habitualmente con un tamaño de 128).

En este trabajo se utiliza SIFT para extraer los puntos característicos, junto a sus respectivos descriptores, de la imagen inicial y de la imagen patrón.

b) *Matching:* Una vez que se obtienen los descriptores asociados a los puntos característicos de la imagen inicial y la imagen patrón, se realiza un matching para obtener los puntos correspondientes entre ambas imágenes. En nuestro caso, se utilizará únicamente la nube de puntos correspondientes de la imagen inicial, los cuales, en su mayoría, estarán ubicados en el interior de la placa vehicular, pero también habrán puntos espurios situados en otros lugares de la imagen, que deben ser excluidos automáticamente.

2) *Segmentación:* En esta etapa se aplican técnicas de agrupamiento para excluir, de forma automática, aquellos puntos correspondientes “espurios” obtenidos en el proceso de matching. Finalmente, mediante la técnica de crecimiento de regiones, se segmenta la placa vehicular.

a) *Agrupamiento (clustering):* La técnica de agrupamiento, también conocida como clasificación no supervisada, es un método para generar grupos de objetos (clusters), de tal manera que aquellos elementos pertenecientes a un mismo cluster tengan un alto grado de similitud entre ellos, y a la vez, un bajo grado de similitud con elementos pertenecientes a otros clusters.

El objetivo de esta etapa es localizar el cluster conformado por los puntos ubicados en la zona de la placa vehicular y además obtener su centroide asociado. Esto se puede lograr debido a que los puntos correspondientes de la imagen inicial, se obtienen utilizando la imagen patrón; es por esto que, generalmente, el cluster que representa a la placa, suele ser aquel que contiene la mayor cantidad de puntos correspondientes “Fig. 2”. Para lograr el objetivo planteado, se aplicaron las técnicas k-means, fuzzy c-means y mean shift; las cuales fueron analizadas y comparadas para ver cual de ellas otorgaba los mejores resultados.




Figura 2. Representación gráfica de agrupamiento utilizando 5 clusters.

a.1) *K-means:* Esta es una técnica paramétrica para el agrupamiento y clasificación de objetos, cuya complejidad es $O(nkl)$, donde n es el número de objetos, k es el número de clusters y l es el número total de iteraciones. K-means realiza la asignación de los elementos dentro de k-clusters basado en la medida de similitud con respecto al centroide de cada cluster; estas iteraciones se realizan hasta que no haya un cambio significativo en la similitud de los objetos con respecto a los centroides.

El algoritmo de agrupamiento k-means funciona de la siguiente manera “Fig. 3”:

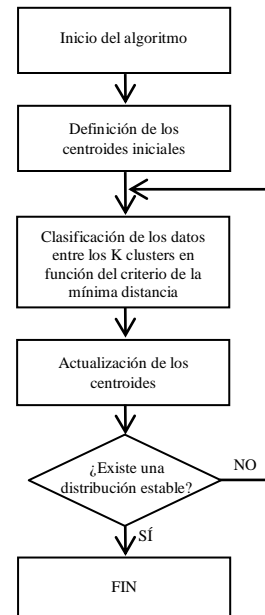


Figura 3. Diagrama genérico del algoritmo k-means.

- Según el funcionamiento de k-means, presentado en [9], el algoritmo recibe como entrada el número de clusters en los que se agruparán los datos y una *matriz de datos* “(2)”, la cual contiene las coordenadas en x e y de cada uno de los puntos que la conforman. Esta matriz de datos está compuesta por todos aquellos puntos característicos correspondientes de la imagen inicial que fueron obtenidos previamente en el proceso de matching.

$$M = \begin{bmatrix} x & y \\ m_{11} & m_{12} \\ m_{21} & m_{22} \\ \vdots & \vdots \\ m_{n1} & m_{n2} \end{bmatrix} \begin{array}{l} \text{punto 1} \\ \text{punto 2} \\ \vdots \\ \text{punto n} \end{array} \quad (2)$$

- Con respecto a los centroides iniciales, no es necesario definirlos como condición a priori, ya que en una primera instancia, se determinan aleatoriamente.
- En la etapa de clasificación, se determina a qué cluster pertenecerá cada punto de la matriz de datos. Para esto se calcula la distancia existente entre el punto en cuestión y cada centroide. La pertenencia de cada punto a un determinado cluster, queda definida por la menor distancia entre el punto y el centroide asociado al cluster. Los tipos de distancias que se utilizaron para lograr la clasificación, fueron: *distancia Euclidiana* “(3)” y *distancia City block* “(4)”.

$$d_{ij} = \sqrt{\sum_{k=1}^n (z_{kj} - v_{ki})^2} \quad (3)$$

$$d_{ij} = \sum_{k=1}^n |z_{kj} - v_{ki}| \quad (4)$$

En donde:

- $k=1 \dots n$ (n representa el número de variables para representar un punto, plano $n=2$).
- $i=1 \dots c$ (c representa el número de clusters).
- $j=1 \dots N$ (N representa el número de puntos de cada variable).
- Las distancias calculadas se almacenan en una *matriz de distancias* “(5)” de $n \times c$, donde n corresponde al número de puntos de la matriz de datos y c al número centroides. Mientras que la pertenencia de cada punto a un determinado cluster, se almacena en una *matriz de pertenencias* “(6)”.

$$D = \begin{bmatrix} c_1 & \dots & c_c \\ d_{11} & \dots & d_{1c} \\ d_{21} & \dots & d_{2c} \\ \vdots & & \vdots \\ d_{n1} & \dots & d_{nc} \end{bmatrix} \quad (5)$$

$$U = \begin{bmatrix} c_1 & \dots & c_c \\ u_{11} & \dots & u_{1c} \\ u_{21} & \dots & u_{2c} \\ \vdots & & \vdots \\ u_{n1} & \dots & u_{nc} \end{bmatrix} \quad (6)$$

- En la etapa de actualización de centroides, para cada cluster generado en la etapa anterior, se calcula su centroide mediante la media. Estos se almacenan en una *matriz de centroides* “(7)” de $c \times 2$, la cual contiene las coordenadas en x e y de los c centroides obtenidos.

$$C = \begin{bmatrix} x & y \\ c_{11} & c_{12} \\ \vdots & \vdots \\ c_{n1} & c_{n2} \end{bmatrix} \begin{array}{l} \text{centroide 1} \\ \vdots \\ \text{centroide n} \end{array} \quad (7)$$

- Finalmente, en la etapa de condición de convergencia, se definió alcanzar un número de iteraciones suficiente hasta que los c centroides no cambien de posición. Si la condición de convergencia no se satisface, se repiten las etapas anteriores del algoritmo hasta alcanzarla.

a.2) *Fuzzy c-means*: Esta técnica de agrupamiento difusa, utilizada en [10], permite conocer el grado con que los elementos son agrupados. Esta ambigüedad (fuzziness) refleja el hecho de que un elemento del conjunto de datos no pueda ser claramente asignado a un cluster y descartado del resto. El grado de fuzziness de un elemento está dado por un coeficiente, por lo que, un valor elevado del mismo significa que el elemento tiene una alta ambigüedad en su asignación.

Este algoritmo constituye una técnica paramétrica para la optimización de la siguiente *función objetivo* “(8)”.

$$J(U, c_1, \dots, c_c) = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m d_{ij}^2 \quad (8)$$

En donde:

- $i=1 \dots c$ (c representa el número de clusters).
- $j=1 \dots n$ (n representa el número de puntos de cada variable).
- U es la matriz de pertenencias de tamaño $n \times c$. En este sentido, el elemento u_{kl} representa el grado de fuzziness que tiene el i -ésimo dato respecto al cluster c_j . Mientras que m es el cociente que controla el grado de pertenencia.
- d_{ij}^2 es la medida de similitud definida, la cual se basa en el criterio del error cuadrático.

El algoritmo de agrupamiento fuzzy c-means funciona de la siguiente manera “Fig. 4”:

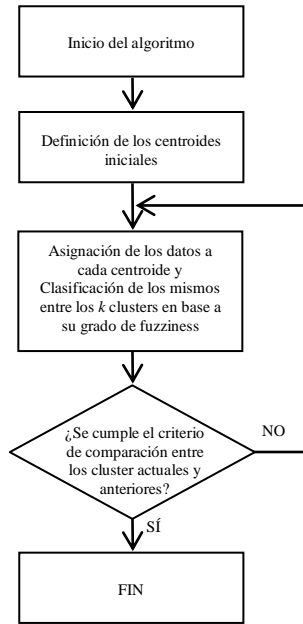


Figura 4. Diagrama genérico del algoritmo fuzzy c-means.

- En la etapa de inicialización, el algoritmo fuzzy c-means recibe como entrada el número de clusters en los que se agruparán los datos y una matriz de datos. Se inicializa la matriz de pertenencias y se define el coeficiente de pertenencia m .
- Con respecto a los centroides iniciales, no es necesario definirlos como condición a priori, ya que en una primera instancia, se determinan aleatoriamente.
- La etapa de clasificación se compone de 2 partes. En primer lugar se asignan los puntos a cada cluster, en función del criterio de la mínima distancia. Luego se calcula el grado de fuzziness que posee cada punto dentro del cluster al cual pertenecen.
- Finalmente, se verifica la *condición de convergencia de fuzzy c-means* “(9)”.

$$\|U^{(i)} - U^{(i-1)}\| \leq \epsilon_F \quad (9)$$

En donde:

- $U^{(i)}$ es la matriz de pertenencias de la iteración actual.
 - $U^{(i-1)}$ es la matriz de pertenencias de la iteración anterior.
 - ϵ_F es un criterio de particionado para los centroides de los clusters.
- La condición de convergencia consiste en una comparación entre los valores de las matrices de pertenencias calculadas recientemente y el factor de

particionado para los centroides de los clusters. Si la diferencia entre las matrices de pertenencias es menor al factor de particionado, el algoritmo finaliza. En caso contrario se repiten las etapas anteriores del algoritmo hasta alcanzarla. Cabe señalar, que este procedimiento cuenta con un número máximo de iteraciones para ser realizado.

a.3) *Mean shift*: Este método, presentado por primera vez en [11], constituye una técnica de agrupamiento no paramétrica basada en densidad. Mean shift, en contraste con k-means y fuzzy c-means, no requiere conocer a priori el número de clusters en los que se distribuirán los datos.

Este algoritmo trata el problema de agrupamiento de un espacio d-dimensional como una *función de densidad de probabilidad* “(10)”, donde las regiones corresponden a los máximos, estos puntos máximos son interpretados como el centroide de los objetos. Para cada punto de los datos por agrupar, se realiza un procedimiento para calcular el gradiente de la función de densidad hasta su convergencia.

$$\hat{f}(x) = \frac{1}{nh^d} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right) \quad (10)$$

En donde:

- $i=1 \dots n$ (n representa el número de puntos).
- $d=2$ (ya que los puntos pertenecen a un espacio de 2 dimensiones).
- x_1, \dots, x_n son los puntos del conjunto de datos.
- K es el *kernel* para hallar la función de densidad.
- h es el valor de *ancho de banda* a definir.

b) *Crecimiento de regiones*: En esta etapa se recibe la imagen inicial y el centroide asociado a la región que se desea segmentar. El resultado de aplicar esta técnica, es una sub-imagen que corresponde a la menor región que encapsula al centroide.

Cabe señalar que este proceso debe ser controlado, debido a que, en algunas situaciones, el centroide puede situarse en el interior de la región de un carácter de la placa patente, por lo que se generará una segmentación inválida que no corresponderá a la placa vehicular. Esta situación puede ser evitada, ya que se conoce el total de píxeles aproximados que ocupa la placa patente dentro de la imagen inicial. De esta manera, el centroide puede ser desplazado hasta quedar situado fuera del carácter y rodeado únicamente por el marco de la placa; situación que generará una segmentación válida que corresponderá justamente a la patente vehicular que pasará finalmente a la etapa de reconocimiento de caracteres, en la cual existen diversas técnicas, como por ejemplo Redes Neuronales o Reconocimiento Óptico de Caracteres (OCR).

III. PRUEBAS Y RESULTADOS

Las pruebas fueron realizadas en Matlab®. Se utilizó un computador Intel® Core™2 Duo CPU T6600 de 2.20 GHz. de velocidad y 2,00 GB de memoria RAM.

Se capturaron imágenes VGA (4:3) de 640x480 píxeles con dos cámaras digitales: SAMSUNG Digimax A40 de 4.0 megapíxeles y SONY DSC-HX9V de 16.2 megapíxeles.

A. Pruebas

1) *Imágenes de prueba:* Para realizar las pruebas generales, se tomaron 45 imágenes, al azar, de vistas frontales y traseras de vehículos chilenos, peruanos, bolivianos y argentinos, estacionados en las calles de la ciudad “Fig.5”.




Figura 5. Parte del set de imágenes que se tomaron para realizar las pruebas.

2) *Detección:* En una primera instancia, se detectan, mediante SIFT, los *puntos característicos* y *descriptores* de la imagen de prueba “Fig. 6”.

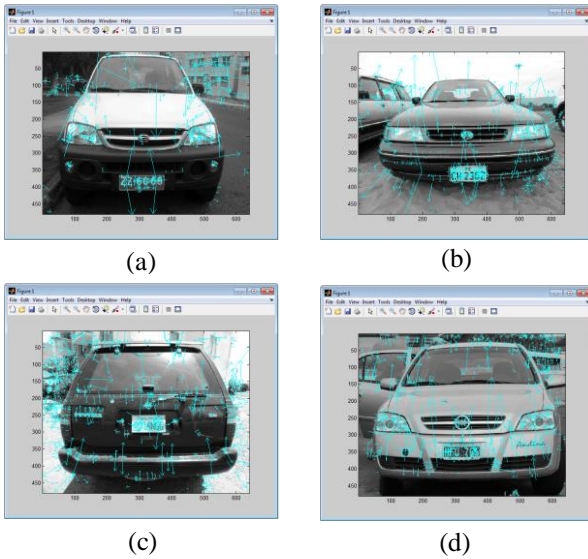


Figura 6. SIFT: Puntos característicos y descriptores asociados de 4 imágenes de prueba:
 (a) img. N°6 chileno [630 pts.], (b) img. N°8 peruano [817 pts.],
 (c) img. N°25 boliviano [1302 pts.], (d) img. N°33 argentino [955 pts.].

Una vez que se obtienen los puntos característicos de la imagen de prueba, se realiza un *matching* entre los descriptores de dicha imagen y los descriptores de la imagen patrón. En este proceso se determinan los puntos correspondientes entre ambas imágenes, utilizando un valor de umbral para controlar la cantidad de correspondencias requeridas “Fig. 7”.

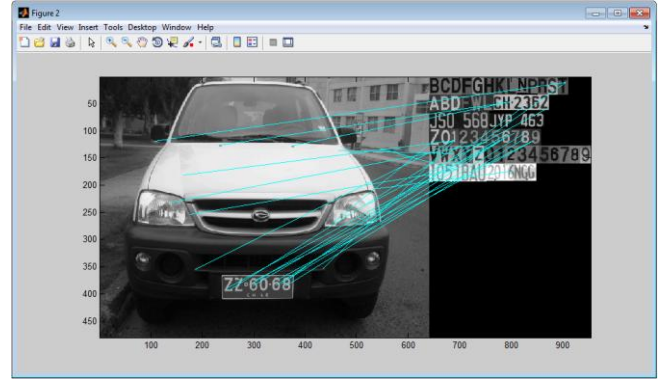
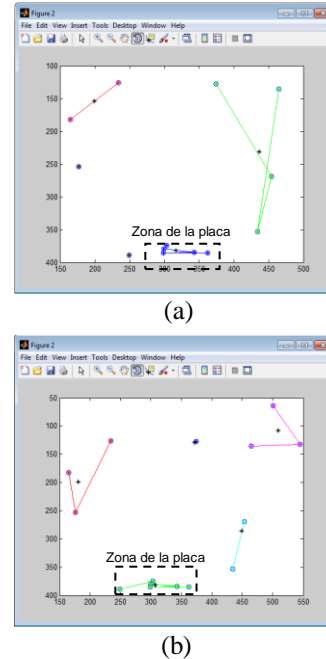
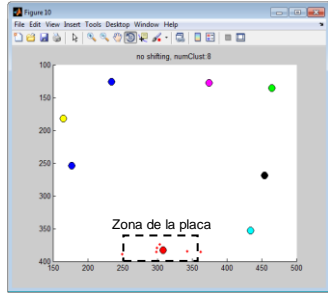


Figura 7. Puntos correspondientes entre la imagen de prueba N°6 y la imagen patrón [umbral = 0.80, pts. correspondientes = 39].

3) *Segmentación:* Luego de obtener los puntos correspondientes de la imagen de prueba, se aplican *técnicas de agrupamiento* para localizar el cluster conformado por los puntos ubicados en la zona de la placa vehicular y obtener su centroide asociado.

En la “Fig. 8” se muestra como se distribuyen los puntos correspondientes de una misma imagen de prueba, en los respectivos clusters, dependiendo de la técnica de agrupamiento utilizada.





(c)

Figura 8. Representación gráfica de las 3 técnicas de agrupamiento aplicadas en la imagen de prueba N°6:

- (a) k-means [5 iteraciones, 5 clusters, distancia City block],
 (b) fuzzy c-means [50 iteraciones máx., 5 clusters, exp. matriz de pertenencia = 2, dif. variaciones de centroides = 1e-5],
 (c) mean shift [ancho de banda = 50].

Una vez que se obtiene el centroide del cluster que representa a la placa vehicular, este se utiliza como un “*pixel semilla*” en la etapa de *crecimiento de regiones*. Aquí se segmenta el área mínima que encapsula al centroide, la cual corresponde justamente a la patente vehicular “Fig. 9”.




Figura 9. Patente vehicular segmentada:

- (a) patente chilena [img. N°6], (b) patente peruana [img. N°8],
 (c) patente boliviana [img. N°25], (d) patente argentina [img. N°33].

B. Resultados

La Tabla I, muestra una comparación del número de detecciones exitosas que se obtuvo utilizando la técnica de agrupamiento k-means (5 iteraciones), empleando diferentes medidas de distancia (Euclidiana, City block) y número de clusters (2, 5).

La Tabla II, muestra una comparación del número de detecciones exitosas y los tiempos de ejecución obtenidos en Matlab®, infiriendo de acuerdo a la experiencia el tiempo de ejecución en milisegundos para el caso compilado, del proceso de detección de la placa patente, según la técnica de agrupamiento utilizada.

TABLA I. NÚMERO DE DETECCIONES EXITOSAS CON K-MEANS (5 ITERACIONES) UTILIZANDO DIFERENTES MEDIDAS DE DISTANCIA Y NÚMERO DE CLUSTERS.

Distancia	N° de aciertos	
	2 clusters	5 clusters
Euclideana	10	36
City block	37	40

TABLA II. NÚMERO DE DETECCIONES EXITOSAS Y TIEMPOS DE EJECUCIÓN, EN MILLISEGUNDOS, DEL PROCESO DE DETECCIÓN DE LA PLACA PATENTE, SEGÚN LA TÉCNICA DE AGRUPAMIENTO UTILIZADA.

Agrupamiento	N° de aciertos	Tiempos en milisegundos		
		mín.	máx.	Promedio
K-means ^a	40	21	36	30
Fuzzy c-means ^b	41	21	39	29
Mean shift ^c	44	21	38	28

- a. 5 iteraciones, 5 clusters, distancia City block.
 b. 50 iteraciones máx., 5 clusters, exp. matriz de pertenencia = 2, dif. variaciones centroides = 1e-5.
 c. ancho de banda = 50.

De las 3 técnicas de agrupamiento que fueron utilizadas en el proceso de detección de la placa vehicular, mean shift^c fue la que proporcionó los mejores resultados en cuanto a número de detecciones exitosas y tiempo de ejecución. Con esta técnica se lograron detectar 44 imágenes de las 45 disponibles, obteniendo así un 97,7% de porcentaje de acierto en la detección de la placa patente. Mientras que las técnicas k-means^a y fuzzy c-means^b, obtuvieron un porcentaje de acierto del 88,9% y 91,1% respectivamente.

Cabe destacar que la conversión del código a lenguaje C/C++ reduciría significativamente los tiempos de ejecución obtenidos al orden de los milisegundos, lo cual es clave para una futura implementación, puesto que el tiempo es una variable crítica en este tipo de sistemas.

IV. CONCLUSIONES

La utilización de SIFT para detectar los puntos característicos de la imagen inicial y la imagen patrón que contiene los posibles caracteres de una placa patente, es fundamental para el proceso de detección en ambientes externos, puesto que se trata de un detector que proporciona invariancia a ciertos aspectos de la placa (rotación, escala, traslación y en cierta medida al cambio de iluminación) y además genera los descriptores necesarios para realizar el proceso de matching.

La aplicación de técnicas de agrupamiento, es primordial para eliminar de forma automática, los puntos espurios que entrega el proceso de matching. Éstas técnicas nos permiten obtener el cluster que representa a la placa y su centroide asociado, el cual se utiliza para segmentar la placa vehicular mediante la técnica de crecimiento de regiones.

Con respecto a las distancias utilizadas en K-means, Euclidiana responde de mejor manera a mayor cantidad de

clusters. Mientras que la distancia City block resulta ser la más estable y la que mejores resultados entrega, independientemente del número de clusters empleados. Esto se debe a que tanto Euclidiana como City block, tienen un concepto distinto de “distancia”. Para Euclidiana, la distancia mínima entre dos puntos, es la recta directa que los une, mientras que City block se mueve a lo largo de los ejes horizontales y verticales. De esta forma, para un mismo par de puntos, se van a obtener distintos valores de distancias, siendo City block, la que mejores resultados entregó.

Finalmente se puede decir que este método logra detectar placas patentes en ambientes externos de manera satisfactoria y en un bajo tiempo de ejecución. De igual manera se continuarán investigando nuevas técnicas de agrupamiento y se compararán con las ya consideradas, de manera de adoptar la técnica que permita obtener los mejores resultados, con la finalidad de poder aplicarla en sistemas orientados al control de acceso y/o flujo vehicular.

REFERENCIAS

- [1] F. Martín Rodríguez, X. Fernández Hermida, “Un nuevo método, basado en morfología, para la localización de matrículas”. Departamento de Tecnologías de las Comunicaciones. Universidad de Vigo, España, 2000.
- [2] S. Rovetta, R. Zunino, “License-Plate Localization by Using Vector Quantization”, ICASSP’99, pp. 1113-1116 vol.2. 1999.
- [3] F. Wang, L. Man, B. Wang, Y. Xiao, W. Pan, X. Lu, “Fuzzy-based algorithm for color recognition of license plates,” Institute of Image and Graphics, School of Computer Science, Sichuan University, Chengdu 610064, Sichuan, PR China, Department of Computer Science, Zhongyuan University of Technology, Zhengzhou 450007, Henan, PR China, Febrero 2008.
- [4] J. Jiao, Q. Ye, Q. Huang, “A configurable method for multi-style license plate recognition”. Graduate University of Chinese Academy of Sciences, No.19A, Yuquan Road, Beijing 100049, PRChina, Agosto 2008.
- [5] V. Abolghasemi, A. Ahmadyfard, “An edge-based color-aided method for license plate detection,” Faculty of Electrical Engineering and Robotic, Shahrood University of Technology, Shahrood, Iran, Octubre 2008.
- [6] J. Rojas Henríquez, D. Aracena Pizarro, “Detección y Reconocimiento de patentes vehiculares por Visión Computacional”, CISAISI 2009, EUIIIS: Escuela Universitaria de Ingeniería Industrial Informática y Sistemas, Universidad de Tarapacá, Arica, Octubre, 2009.
- [7] M. Zahedia, S. Mahdi Salehia, “License Plate Recognition System Based on SIFT Features,” School of Computer Engineering and Information Technology, Shahrood University of Technology, Shahrood, Iran, 2010.
- [8] D. Lowe, “Distinctive Image Features From Scale Invariant Keypoints”, International Journal of Computer Vision, vol.60, no.2, pp. 91-110, University Of British Columbia, Canadá, Enero 2004.
- [9] C. García Cambronero, I. Gómez Moreno “Algoritmos de Aprendizaje: knn & kmeans”, Inteligencia en Redes de Comunicación, Universidad Carlos III de Madrid.
- [10] G. Flores Chapa, “Conteo de Objetos en Flujos de Video H.264”, Universidad Autónoma Metropolitana, Noviembre 2011.
- [11] K. Fukunaga, L.D. Hostetler, “The estimation of the gradient of a density function, with applications in pattern recognition”, IEEE Trans. Information Theory, vol.21, pp. 32-40, 1975.