



UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MÉXICO



CENTRO UNIVERSITARIO UAEM TEXCOCO

**RECONOCIMIENTO AUTOMÁTICO DE MATRÍCULAS
DE AUTOMÓVILES PARTICULARES MEXICANOS**

T E S I S

**QUE PARA OBTENER EL GRADO DE:
MAESTRO EN CIENCIAS DE LA COMPUTACIÓN**

PRESENTA:

JOSUÉ ERICK ESPINOZA MORALES

TUTOR ACADÉMICO:

DR. EN C.COM. FARID GARCÍA LAMONT

TUTORES ADJUNTOS:

DR. EN C. JAIR CERVANTES CANALES

M. EN C.C.A. JOSÉ SERGIO RUÍZ CASTILLA

TEXCOCO, ESTADO DE MÉXICO, DICIEMBRE DE 2015.



DICTÁMEN DE AUTORIZACIÓN Y OBTENCIÓN DE GRADO DE MAESTRÍA

Texcoco, Méx. , a 17 de noviembre del 2015

Título del proyecto:

Reconocimiento Automático de Matrículas de Automóviles Particulares Mexicanos

Tesista:

Espinoza Morales Josué Erick

Dictamen:

No. de revisión: 2

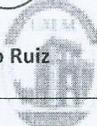
- Rechazado
- Sujeto a modificaciones
- Aceptado, condicionado
- Aceptado

**POSGRADO
TITULACION
RECIBIDO**
 Por Adriana Arévalo
 Texcoco, Méx., a 19 de 11 del 2015

Observaciones generales:

Aceptado para la impresión
 Aceptado para la defensa de grado

Tutor Adjunto	Tutor Académico	Tutor Adjunto
Dr. en C. Jair Cervantes Canales	Dr. en C. Com. Farid García Lamont	M. en C. C.A. José Sergio Ruiz Castilla



Agradecimientos

Agradezco a Dios por brindarme la oportunidad de comenzar y concluir con esta etapa de mi vida a pesar de las dificultades.

A mis padres por el apoyo que me han brindado a lo largo de mi vida en momentos buenos y malos y por que han sido un buen ejemplo para mi y mis hermanos.

A mis profesores por compartir sus conocimientos y experiencias que me han servido para definir mi camino a seguir.

Al Dr. Farid García Lamont por su asesoría y paciencia como mi tutor académico en el desarrollo de esta investigación.

Al Dr. Jair Cervantes Canales y al M. en C.C. José Sergio Ruiz Castilla por su tiempo en las revisiones de mi trabajo.

A la Universidad Autónoma del Estado de México y al Consejo Nacional de Ciencia y Tecnología por la beca que me permitió realizar mis estudios de maestría.

Índice general

Índice de figuras.....	IV
Índice de tablas.....	V
Resumen.....	VI
Abstract.....	VII
1 Introducción.....	1
1.1 Planteamiento del problema.....	2
1.2 Objetivo general.....	3
1.3 Objetivos específicos.....	3
1.4 Justificación.....	4
2 Antecedentes y trabajos previos.....	5
2.1 Pre-procesamiento de la imagen.....	5
2.2 Segmentación de caracteres.....	7
2.3 Reconocimiento de caracteres.....	11
3 Propuesta para el reconocimiento de matrículas empleando imágenes digitales.....	15
3.1 Segmentación.....	16
3.2 Modelado de los caracteres.....	20
3.2.1 Momentos de Hu.....	21
3.2.2 Descriptores de Fourier.....	21
3.3 Clasificador Bayesiano.....	22
3.4 Análisis de Componentes Principales.....	23
4 Experimentos y resultados.....	25
4.1 Pruebas de reconocimiento de caracteres.....	25
4.2 Pruebas de reconocimiento de matrículas.....	30
5 Discusión de resultados.....	35
5.1 Patrones de textura complejos y marcas de agua en los caracteres.....	35
5.2 Iluminación no uniforme.....	38

6	Conclusiones y trabajo futuro	41
	Referencias.....	43
	Apéndice A.....	47

Índice de figuras

Figura 1.1. Ejemplos de placas vehiculares. (a) placa de la Unión Europea, (b) placa china y (c) placa mexicana con patrones de textura en el fondo.	1
Figura 1.2. Resultados de matrículas mexicanas procesadas con el método de Otsu (1979). Imágenes originales (a), (c) y (e); (b), (d) y (f) imágenes binarias obtenidas.	2
Figura 3.1. Diagrama de flujo del proceso de reconocimiento de placas.	15
Figura 3.2. Dimensiones en milímetros de las matrículas de automóviles particulares mexicanos según la Norma Oficial Mexicana NOM-001-SCT-2-2000.	16
Figura 3.3. Ejemplo de imágenes obtenidas con diferentes enfoques de procesamiento: (a) y (b) imágenes de entrada; (b) y (e) imágenes obtenidas con el algoritmo propuesto por Sedighi and Vafadust (2011); (c) y (f) imágenes obtenidas usando la propuesta de Zheng et al. (2013).	17
Figura 3.4. (a) y (b) imágenes obtenidas al asignar 1's al 20% de los píxeles con las intensidades más bajas y poniendo en 0 a los demás píxeles de las imágenes Figura 3.3 (a) y (d).	19
Figura 3.5. Mascaras (a) y (b) empleadas para las operaciones de erosión y dilatación, respectivamente.	19
Figura 3.6. (a) y (c) imágenes obtenidas después de la erosión y dilatación de las imágenes de la Figura 3.4, (b) y (d) imágenes obtenidas después de eliminar objetos no deseados.	20
Figura 4.1 (c) Casos especiales que dificultaron la segmentación de los caracteres. a) Placa con caracteres claros. b) Placa con colores de fondo oscuros. c) Caracteres con marca de agua.	32
Figura 5.1. Placas de vehículos mexicanos pertenecientes al mismo Estado pero con diferentes diseños. (a) y (b) placas del Estado de Jalisco; (c) y (d) placas del Estado de Sinaloa.	36
Figura 5.2. Placa vehicular del Estado de Tlaxcala.	37
Figura 5.3. Placas con marcas de agua en los caracteres.	37
Figura 5.4. Imágenes de placas de vehículos con iluminación no uniforme.	38

Índice de tablas

Tabla 4.1. Total de muestras por clase de carácter para las pruebas de reconocimiento.....	26
Tabla 4.2. Resultados de identificación de caracteres con el 30% de datos de prueba	27
Tabla 4.3. Resultados de identificación de caracteres aplicando componentes principales al conjunto de datos.....	29
Tabla 4.4. Resultados de identificación de placas por Estado.....	30
Tabla 4.5. Resultados de identificación de placas por Estado utilizando componentes principales .	33

Resumen

En este trabajo se presenta una propuesta para la identificación de matrículas de automóviles mexicanos considerando las etapas de segmentación e identificación. Las técnicas existentes en el estado del arte para la identificación de matrículas de automóviles son efectivas para matrículas cuyo color de fondo es uniforme y no contienen patrones de textura; además, estas matrículas tienen un alto contraste entre los colores de fondo y caracteres. Las técnicas utilizadas funcionan considerando estos supuestos, pero para el caso de las matrículas mexicanas no siempre reconocen exitosamente las matrículas debido a que estas tienen características diferentes a la mayoría de los países.

Para abordar este problema en el enfoque propuesto se emplea información sobre la norma de fabricación de placas mexicanas, establecida por el gobierno federal. Una de las características que deben cubrir las placas es respecto a las dimensiones de los caracteres, en donde sumando las áreas que ocupan todos los caracteres, la proporción de área que ocupa el conjunto de letras respecto al área de la placa es del 20%. En consecuencia, en una imagen digital, el 20% de los píxeles son ocupados por las letras de la matrícula. Por otra parte, la intensidad de los colores de los caracteres es menor al de los colores del fondo de la placa con el fin de crear alto contraste y así facilitar el reconocimiento de la matrícula.

En la etapa de segmentación se utiliza un enfoque similar al propuesto por (Zhang & Zhang, 2003), en el cual para segmentar los caracteres se acentúa la intensidad del 20% de los píxeles con las intensidades más altas, ya que se asume que estos píxeles corresponden a los caracteres. Los pasos propuestos para el reconocimiento de matrículas son: 1) segmentación de caracteres, 2) reconocimiento de los caracteres. Una vez segmentados los caracteres, estos se modelan con descriptores de Fourier y Momentos de Hu. Finalmente en la etapa de identificación se realizaron dos tipos de pruebas con un clasificador bayesiano. La primera tomando todas las características extraídas y la segunda reduciendo la dimensionalidad de los vectores de características usando análisis de componentes principales con el fin de reducir el costo computacional.

Abstract

This paper presents a proposal for Mexican license plate identification considering the segmentation and identification stages. The current techniques used for license plate identification are effective only for plates with uniform background color and without texture patterns. Furthermore, these plates have high contrast between the background colors and the characters. The techniques used, considering these assumptions, work, but Mexican license plates are not always successfully recognized because they have different characteristics from those of most countries.

To solve this problem, the proposed approach uses the established information in the Mexican plate manufacturing standards established by the Federal Government. One of the standards which plates should cover is the size of the characters, by adding the areas occupied by the characters, the area ratio of the characters respect the plate area is 20%. Thus, in one digital image, the 20% of the pixels are character pixels. Moreover, the intensity of the character colors is lower than the background colors in order to increment the contrast and facilitate the plate recognition.

In the segmentation step, an approach similar to the (Zhang & Zhang, 2003) approach is used. In that approach the intensity of the 20% of the pixels is accented with the highest intensity rates to segment the characters, since it is assumed that these pixels correspond to the character pixels. The proposed steps to the plate recognition are: 1) character segmentation and 2) character recognition. After the characters are segmented, they are modeled using Fourier descriptors and Hu moments. Finally in the identification step, two types of test using a Bayesian classifier were performed. In the first test, all the extracted features were considered and in the second test, the dimensionality of feature vectors using the main analysis components were reduced in order to decrease the computational cost.

1 Introducción

Los sistemas de reconocimiento automático de matrículas vehiculares pertenecen a una de las líneas de investigación del transporte inteligente. Estos han tenido varias aplicaciones; por ejemplo, sistemas de verificación de acceso en puentes y túneles, control de tráfico, monitoreo de límites de velocidad y sistemas de control fronterizo, entre otros.

Existen varias propuestas para la identificación automatizada de placas de automóviles; por ejemplo, identificación por radio frecuencia, redes de sensores inalámbricos y reconocimiento de matrículas vehiculares por visión artificial (Sedighi & Vafadust, 2011; Du et al., 2013). Esta última es la más utilizada y la que se aborda en este trabajo.

Dado que las características de tamaño, color de fondo, textura, número y tipo de caracteres de las placas vehiculares varían de un país a otro, los sistemas de identificación actuales están limitados a reconocer las placas de un determinado país o región de acuerdo a sus características muy particulares. La mayoría de los sistemas de visión artificial para el reconocimiento de placas están diseñados para identificar placas con las características de las placas que se muestran en la Figura 1.1 (a) y (b), en donde se tienen caracteres que contrastan con el fondo pero como principal característica, el fondo de la placa no tienen ningún patrón de textura. Pero no hay trabajos que aborden el problema de las placas mexicanas, en donde la apariencia de estas es muy diferente; en la Figura 1.1 (c) se muestra un ejemplo de una placa mexicana en donde el fondo tiene un patrón complejo de textura.

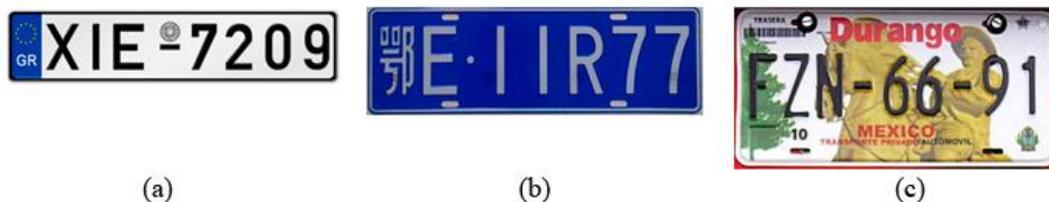


Figura 1.1. Ejemplos de placas vehiculares. (a) placa de la Unión Europea, (b) placa china y (c) placa mexicana con patrones de textura en el fondo.

Los algoritmos que están diseñados para reconocer placas con la apariencia de las placas mostradas en la Figura 1.1 (a) y (b) no siempre son exitosos para reconocer las matrículas, ya que asumen que la placa no tiene patrones de textura en el fondo; siendo que en el caso de las placas mexicanas es muy común que las placas tengan diferentes patrones de textura. En la Figura 1.2 se

muestran las imágenes binarizadas que se obtienen al emplear el método de Otsu (1979) en tres placas mexicanas, siendo este método de binarización uno de los más empleados para el reconocimiento de placas.



Figura 1.2. Resultados de matrículas mexicanas procesadas con el método de Otsu (1979). Imágenes originales (a), (c) y (e); (b), (d) y (f) imágenes binarias obtenidas.

Como se puede ver en la Figura 1.2 (b), (d) y (f), la segmentación de los caracteres no es exitosa porque no se logra separarlos de los patrones de textura del fondo.

Por lo tanto, en este trabajo se presenta la propuesta de un algoritmo para el reconocimiento de las matrículas de vehículos mexicanos. El algoritmo propuesto en esta tesis procesa la imagen de tal forma que los patrones de textura del fondo de la matricula son inhibidos y facilitando la extracción de los caracteres para su posterior reconocimiento.

1.1 Planteamiento del problema

El proceso de reconocimiento automático se vuelve difícil debido a varios factores tales como ruido en la imagen, variaciones en el espacio entre caracteres, el marco de la placa y las variaciones de rotación e iluminación (Zhang & Zhang, 2003).

El caso de identificación de placas vehiculares mexicanas presenta dificultades adicionales debido a que cada estado de la república crea su propio diseño, esto implica que las placas entre los distintos estados tengan diferente fondo, color y textura.

Por otra parte, el diseño de las placas también puede cambiar dependiendo de la administración en turno de cada estado de la república. Debe considerarse también que existe una variante en el número de caracteres de las placas del Distrito Federal y el resto de los estados, cinco y seis caracteres respectivamente.

Es importante remarcar que en este trabajo solo se aborda el caso de las placas de vehículos adscritos fuera del Distrito Federal, ya que es complicado poder determinar la cantidad exacta de caracteres que tiene una placa. Al acotarlo a solo reconocer placas de vehículos que no sean del Distrito Federal, se conoce de antemano la cantidad exacta de caracteres que se deben extraer, en este caso es de siete caracteres.

El problema con las placas de automóviles mexicanos es que estas tienen patrones de textura en el fondo, si se aplican los métodos convencionales de reconocimiento de placas la extracción de los caracteres no es exitosa porque los patrones de textura distorsionan la apariencia de los caracteres. En los trabajos relacionados se asume que las placas no tienen patrones de textura en su fondo y que las letras ocupan casi toda la altura de las placas (Du, et al., 2013; Zheng, et al., 2013).

1.2 Objetivo general

Desarrollar un algoritmo de visión artificial que identifique automáticamente la matrícula de la placa de automóviles particulares de cualquier entidad federativa mexicana fuera del Distrito Federal.

1.3 Objetivos específicos

- Desarrollar un algoritmo que extraiga los caracteres de las placas de vehículos mexicanos.
- Desarrollar un algoritmo para reconocer los caracteres extraídos.

1.4 Justificación

Anteriormente se ha mencionado que existe un gran campo de aplicación para los sistemas de reconocimiento de placas vehiculares; por esta razón se ha trabajado por varios años desarrollando y mejorando los procesos y algoritmos que contribuyan a efectuar esta tarea de una manera más eficiente.

El resultado de la investigación aportará una propuesta que solucione el problema de las diferentes características de placas vehiculares en México o en algún otro país donde tengan un problema similar, pero además servirá como punto de partida para aplicarlo en diversos sistemas vehiculares que requieran de la identificación automática de placas en México.

2 Antecedentes y trabajos previos

La mayor parte de los autores en la bibliografía consultada definen el proceso de reconocimiento de matrículas vehiculares en tres etapas: detección de la placa, segmentación de caracteres y reconocimiento de caracteres. En este trabajo solo se aborda los problemas de segmentación y reconocimiento de caracteres.

2.1 Pre-procesamiento de la imagen

Por lo general las imágenes de las placas son adquiridas con variaciones de iluminación, suciedad, deterioro, entre otros, reduciendo notablemente el rendimiento de los algoritmos en las etapas de segmentación y reconocimiento. Para mejorar los resultados en estas etapas, muchos autores realizan un pre-procesamiento de la imagen antes de la etapa de segmentación aplicando diversas técnicas y algoritmos que permiten mejorar la calidad de la imagen antes de ser segmentada.

En el trabajo de Zhang & Zhang (2003) el procesamiento consiste en tres pasos: normalización de tamaño de la imagen de la placa, determinación del tipo de placa y realce de objetos. En la etapa de normalización se definen las dimensiones de los caracteres a 160×40 píxeles. El tipo de placa se determina por medio del análisis del histograma de la imagen en escala de grises, una vez determinado se estandarizan las imágenes a caracteres blancos con fondo negro. Finalmente en la etapa de realce de objetos se considera la proporción entre caracteres y el resto de la placa. Se considera que el 20% de los píxeles de la imagen binaria corresponden a los caracteres los cuales deben ser resaltados y el resto de píxeles deben ser inhibidos.

El algoritmo de realce consiste en dos pasos:

1. El nivel de grises de todos los píxeles es escalado en un rango de 0 a 100 y comparado con el rango original de 0 a 255. Como resultado, todos los píxeles son disminuidos.
2. Ordenar todos los píxeles por niveles de gris en orden descendente y multiplicar el 20% de los píxeles del nivel superior de gris por 2.55.

En Sedighi & Vafadust (2011) se adquiere la imagen a una distancia de entre 1.5 y 2.5 metros en la cual se le aplica un filtro Gaussiano a sus componentes RGB con la finalidad de disminuir los

efectos de la iluminación no uniforme y el ruido. Este filtro hace que los colores en la imagen sean más uniformes aun si la imagen está deteriorada. Posteriormente se aplica una transformación laplaciana que aclara los bordes de la imagen con el fin de uniformizar y separar el fondo de los caracteres. Por último la imagen obtenida es procesada a su equivalente en escala de grises. El siguiente paso es efectuar un proceso de binarización de la imagen usando umbralización por medio del método Otsu (1979).

En Gazcón, Chesnevar, & Castro (2012) se obtiene la imagen en RGB y se ajusta la resolución a 300×200 pixels, finalmente la imagen es transformada a escala de grises. En Giannoukos et al. (2010) se redimensiona la imagen a 200×50 pixeles usando interpolación bicubica. Posteriormente es binarizada usando una técnica de umbral adaptativo en la cual se calcula la media y varianza para cada pixel considerando sus $k \times k$ pixeles vecinos.

Kocer & Cevik (2011) realizan una ecualización del histograma a la imagen en escala de grises para aumentar el contraste, posteriormente es usado el filtro de la mediana para eliminar las regiones con ruido en la imagen. En este método de filtrado, una matriz de 3×3 es aplicado a la imagen. Los pasos son los siguientes:

1. Un pixel es elegido como el centro de la matriz
2. Los pixeles del contorno son asignados como pixeles vecinos
3. Se emplea un proceso de ordenamiento de entre los 9 pixeles de menor a mayor.
4. El quinto elemento es considerado como elemento medio.
5. Este procedimiento es implementado para todos los pixeles de la imagen.

Zhang & Wang (2012) convierten la imagen de color en escala de grises usando la siguiente transformación: $g(i, j) = 0.11 \times R(i, j) + 0.59 \times G(i, j) + 0.3 \times B(i, j)$. Para el realce de los caracteres se usa el método de histograma balanceado.

En Zhu et al. (2011) se obtiene primero la información de color en modelo HSV y posteriormente se invierten las imágenes cuyo fondo es amarillo o blanco con el objetivo de obtener resultados uniformes en el proceso de binarización. Para la binarización se usa el método de basado en el valor local extremo, el cual es un método de binarización local.

Zheng et al. (2013) definen un método para uniformizar los diferentes estilos de placas, obteniendo al final un fondo negro con caracteres blancos. El cambio de color se hace trazando líneas simétricas horizontales con el fin de obtener los puntos de cruce (donde el valor de los pixeles cambian de negro a blanco) a lo largo de cada línea horizontal. El número de puntos de

cruce se incrementa en uno si es un punto del primer plano (perteneciente a un carácter de la placa). Si el valor del índice de color está por encima de un umbral estadístico seleccionado, la imagen es etiquetada como candidata a ser convertida; de lo contrario se mantiene igual. Por lo tanto se asume que todas las placas candidatas son negro sobre blanco, con esto se mantiene la consistencia del área de interés.

Considerando también que las imágenes contienen bordes que no pertenecen a la placa, se realiza un proceso de alargado. El siguiente paso es detectar los bordes verticales de la placa mediante un gradiente horizontal. Para cada pixel se usa la mascara $[-3 \ 0 \ 3; -10 \ 0 \ 10; -3 \ 0 \ 3]$ para procesar el valor del gradiente horizontal. Posteriormente se usa el método Otsu (1979) para binarización y obtener los mapas verticales. Los bordes de los pixeles son representados usando pixeles blancos y los restantes como pixeles negros.

2.2 Segmentación de caracteres

El proceso de segmentación consiste en extraer los caracteres de la placa para su posterior reconocimiento.

En el método propuesto por Sedighi & Vafadust (2011) primero se obtiene el negativo de la imagen binaria la cual contiene regiones negras con conectividad 8 sobre un fondo blanco. Posteriormente realiza una búsqueda e identificación de los ocho caracteres. Con este fin utiliza algunas características primitivas de la placa como: altura, anchura, área, promedio de altura y anchura, y desviación estándar de las proporciones de la placa. Posteriormente obtiene otro tipo de características llamadas características relativas las cuales se obtienen calculando los promedios de las características primitivas. Una vez obtenidas las imágenes para cada carácter individual se aplica un filtro Gaussiano que reducirá los efectos de la iluminación no uniforme.

En Zhang & Zhang (2003) se realiza primero una segmentación horizontal encontrando los valles de la proyección vertical dividiendo la imagen en varios bloques. Después se obtiene la línea de segmentación horizontal de cada bloque analizando la proyección horizontal. Por último se utiliza la transformación de Hough en los puntos intermedios de cada subsección para eliminar las líneas de subsección incorrectas y combinando las correctas en una sola. La transformación de Hough se usa para reducir los problemas de rotación de la placa. Posteriormente se realiza un proceso de segmentación vertical basado en el análisis de proyección apoyado por el conocimiento previo de la imagen (dimensiones de la placa, dimensiones de los caracteres y espaciado) para que

sea más preciso. Primero se buscan las líneas de segmentación vertical candidatas considerando los valles de la proyección vertical, después se estima el tamaño de la placa y de cada carácter usando la posición de las líneas de segmentación horizontal candidatas, después se estiman las posiciones de los bordes izquierdo y derecho del intervalo usando conocimiento previo de las dimensiones.

Finalmente se buscan las mejores líneas de segmentación eligiendo aquellas en las cuales las variaciones de los niveles de gris de los píxeles que atraviesan la línea de segmentación sea menor, si fuera el caso contrario; es decir; la variación fuera mayor sería un indicador de que la línea atraviesa más de un carácter y sería eliminada.

En el trabajo de Jiao, Ye, & Huang (2009), el proceso de segmentación se ejecuta un algoritmo de ecualización de nivel de grises y análisis morfológico para obtener los candidatos a caracteres. En este proceso una imagen de 256 niveles de gris se ajusta a Q niveles de gris, posteriormente se aplica una operación morfológica de cierre en la imagen para obtener regiones conectadas. Para obtener tantos candidatos como sea posible se ajusta el parámetro Q . Para mejorar la segmentación y evitar pérdida de caracteres, los autores proponen combinar el método con un método de binarización local.

Zheng et al. (2013) utilizan la proyección horizontal para encontrar los bordes superior e inferior de los caracteres de la placa. El valor promedio del histograma es usado como umbral para determinar los bordes superior e inferior. El área media cuyo segmento del histograma es mayor que el umbral es tomado como el área delimitada por los bordes superior e inferior. Finalmente la distancia entre los bordes superior e inferior es registrada como la altura de los caracteres. Después de localizar estos bordes, se eliminan las áreas que se encuentran por encima del borde superior y por debajo del borde inferior y el área restante es considerada para la segmentación. El siguiente paso es la binarización de la imagen para la cual se selecciona un umbral determinado por el método Otsu. Se obtiene el histograma con la proyección vertical con el objetivo de encontrar la anchura de los caracteres. Para estimar la anchura después del proceso de segmentación, se toman en cuenta las anchuras de todos los bloques excepto los dos de mayor y los dos de menor anchura. Finalmente se obtiene el promedio de las anchuras de los bloques y el resultado es considerado como la anchura de los caracteres estándar de los caracteres.

Con el procedimiento anterior se obtienen segmentos de los cuales aproximadamente el 70% de los bloques contienen caracteres y el resto deben ser eliminados. Para esto se usa un algoritmo de extracción de detección y eliminación de manchas.

En el trabajo de Deb et al. (2012), las regiones que no son de interés como el borde y las regiones que producen ruido son eliminadas a partir del histograma de la proyección vertical. Una vez eliminados, el histograma resultante contendrá los picos correspondientes a los caracteres. Finalmente se normaliza el tamaño de los caracteres extraídos.

Zhu et al. (2011) proponen un algoritmo que usa proyección vertical con conocimiento previo para ajustar la segmentación. Durante este proceso la anchura esperada del carácter puede ser ajustada dinámicamente, lo cual hace que la proyección sea más flexible.

Kocer & Cevik (2011) utilizan un algoritmo de coloreado llamado *gran objeto binario* (blob). Este algoritmo tiene una arquitectura robusta para determinar regiones cerradas y sin contacto de una imagen binaria. El algoritmo usa una plantilla especial L para escanear la imagen de izquierda a derecha y de arriba hacia abajo. Este procedimiento de escaneo determina las regiones independientes para obtener las conexiones en cuatro direcciones diferentes desde un fondo cuyos valores son ceros. Se aplican cuatro algoritmos blob a la imagen binaria dando como resultado los caracteres segmentados.

Posteriormente los caracteres segmentados son clasificados como letras y números. La imagen de la placa es dividida en tres regiones, la primera formada por dos dígitos numéricos, la segunda por un grupo de una a tres letras y la tercera por un grupo de dos a cuatro dígitos. La imagen es escaneada de izquierda a derecha encontrando los espacios entre caracteres. Si el valor del espacio es mayor a un umbral entonces la región es marcada. Finalmente los números son normalizados a dimensiones de 28×35 píxeles y las letras a dimensiones de 30×40 píxeles.

En el trabajo de Giannoukos et al. (2010) un subsistema de segmentación procesa la imagen identificando los bordes de la placa actual compactando o expandiendo los bordes en la región de la placa. Esto se logra calculando la desviación estándar de los píxeles alrededor de los bordes, entonces los bordes son detectados usando un mínimo local. La imagen de la placa es redimensionada a una resolución de 200×50 píxeles usando una interpolación bicúbica. Posteriormente la imagen procesada es binarizada usando una técnica de umbral adaptativo, donde para cada píxel se calcula la media y varianza de los $k \times k$ vecinos. Las regiones continuas blancas de la imagen binaria son extraídas y comparadas con regiones de caracteres ideales. Las regiones extraídas con características medidas que excedan los límites deseados son eliminadas de los siguientes pasos del algoritmo. Por ejemplo, las aéreas con una proporción cercana a 1 pero de menor altura son eliminadas. Cada región que pasa este filtro es considerada un carácter.

Todas las regiones eliminadas incluyendo aquellas que superan los límites son marcadas en una imagen temporal llamada máscara de filtrado. La máscara de filtrado es aplicada a la imagen de entrada para eliminar cualquier región que no sea parte de los caracteres. La imagen resultante se escanea por segunda vez para localizar con mayor exactitud el centro de cada carácter. Finalmente se buscan espacios entre caracteres consecutivos para identificar por separado letras y números de acuerdo al formato de la placa haciendo más precisa la identificación.

Du et al. (2013) realiza un resumen de los diversos métodos de segmentación de las placas de la siguiente forma:

- **Segmentación usando conectividad de píxeles:** Estos métodos etiquetan los píxeles conectados en la imagen binaria de la imagen. Estos píxeles son alisados y aquellos que tienen el mismo tamaño y proporción de caracteres son considerados caracteres de la placa. Estos métodos fallan al extraer todos los caracteres cuando están juntos o rotos.
- **Segmentación usando proyección de perfiles:** Estos métodos son los comunes, usan el contraste en los colores de fondo y los caracteres de la imagen, algunos utilizan la imagen binaria y otros la información de color. Algunos métodos proyectan la imagen de manera vertical para determinar las posiciones iniciales y finales de los caracteres, para posteriormente proyectarlos de manera horizontal para extraer carácter por carácter. También utilizan otras técnicas de eliminación de ruido análisis de la secuencia de caracteres.
- **Segmentación usando conocimiento previo de caracteres:** Con estos métodos se escanea la imagen en una línea horizontal para encontrar las posiciones de inicio y fin de los caracteres. Además en algunos métodos se redimensiona la imagen al tamaño de una plantilla definida. Después de redimensionarla, las mismas posiciones son extraídas para los caracteres. Su desventaja es que si existen variaciones en la placa, el resultado es la extracción de parte del fondo en lugar de los caracteres.
- **Segmentación usando contornos de caracteres:** Estos métodos utilizan dos procesos; el primero es obtener una ubicación aproximada de cada carácter por medio de una técnica de búsqueda rápida y posteriormente obtiene los bordes exactos por medio de un método especial de búsqueda rápida.
- **Segmentación usando combinación de características:** A pesar de estas diferencias, pueden seleccionarse los algoritmos y técnicas empleadas en estos sistemas con el objetivo de identificar las matrículas de automóviles mexicanos.

- **Pre-procesamiento:** En esta etapa se realiza un pre procesamiento de la imagen con el objetivo de normalizar el tamaño y orientación de la placa, se determina la clasificación de los tipos de placa de acuerdo a los colores de fondo y caracteres, se determinan las proporciones de variación entre pixeles blancos y negros en una imagen en escala de grises y finalmente se realiza un proceso para resaltar los objetos mediante la ecualización del histograma de la imagen.
- **Segmentación horizontal:** Para la segmentación horizontal se utiliza la transformada de Hough para detectar las líneas en la imagen. Para una imagen con rotación, propone un algoritmo que consiste en tres pasos:
 1. Encontrar los valles de la proyección vertical y dividir verticalmente la imagen en varios bloques.
 2. Encontrar la línea de segmentación horizontal para cada bloque analizando la proyección horizontal del bloque (línea de sub sección).
 3. Usar la transformada de Hough en los puntos intermedios de las sub secciones para eliminar las líneas de las sub secciones incorrectas y combinar las correctas en una sola línea.
- **Segmentación Vertical:** La segmentación de la placa está basada en el conocimiento previo de la misma, por ejemplo, el tamaño y el intervalo entre caracteres. El algoritmo es el siguiente:
 1. Encuentra candidatos para las líneas de segmentación vertical (un valle en la proyección vertical es un candidato).
 2. Estimar el tamaño de la placa y de cada carácter usando la información de posición de las líneas de segmentación horizontal y los candidatos.
 3. Estimar la posición del borde izquierdo y derecho de un intervalo grande usando el conocimiento previo del tamaño de los caracteres.

2.3 Reconocimiento de caracteres

Sedighi & Vafadust (2011) usan dos redes neuronales feed-forward con una capa oculta para el reconocimiento de caracteres. El entrenamiento consiste en un conjunto de 20 imágenes de 40×40 pixeles de cada número o carácter. Para reducir el número de neuronas de entrada y en consecuencia reducir la complejidad computacional se utiliza el principio de transformación de componentes procesando cada carácter al espacio de componentes principales utilizando

únicamente los primeros 100 coeficientes. Las redes neuronales tienen una capa oculta con 50 neuronas. El número de neuronas de la capa oculta se determina experimentalmente.

Jiao, Ye, & Huang (2009) usan redes neuronales para el reconocimiento. Primero cada carácter segmentado es ajustado si no cumple con una proporción anchura/altura constante. Se extienden los bordes de la imagen para que cumpla con esta proporción. Posteriormente el carácter es normalizado en bloques de 16×16 píxeles empleando un algoritmo de interpolación lineal. Para enfatizar las características de cada carácter se definen 11 tipos de sub bloques. Para cada sub bloque los valores de los niveles de gris son normalizados de 0 a 1, y son extraídos como nodos de entrada de una red neuronal artificial de tres capas. Los nodos de entrada del mismo sub bloque se conectan con los mismos nodos de la capa oculta. Esta estructura asegura que para cada carácter los mismos sub bloques puedan ser acentuados obteniendo grandes pesos en el proceso de entrenamiento. En la red, hay un total de 448 nodos de entrada construidos por los valores de gris de los píxeles. El número de nodos de salida es igual al número de clases; es decir; para el modelo de reconocimiento de dígitos son 10 nodos; para los alfabéticos 26 y para símbolos se define por el usuario. Para entrenar la red neuronal se utilizaron 3000 muestras alfanuméricas y el algoritmo backpropagation con función sigmoïdal como función de activación entre las capas de la red neuronal.

Después de la segmentación Zhu et al. (2011) obtienen las características de la imagen normalizada de 25×50 píxeles. Las características que se obtienen son llamadas características de malla debido a que contienen la información espacial de la imagen. Primero se determinan las dimensiones de la malla que divide la imagen en $n \times n$ rejillas, en este caso $n = 5$. Posteriormente se calcula la probabilidad de densidad de cada rejilla. Si el valor del píxel es 255 se considera como 1 y como 0 en caso contrario. Por lo tanto la densidad P de rejilla es calculada dividiendo el número de píxeles blancos n_w y el número total de píxeles n_t . Adicionalmente se calculan las proyecciones vertical y horizontal de dimensión n . Finalmente se obtienen los vectores característicos. Para el reconocimiento se utiliza una red neuronal backpropagation con 35 neuronas de entrada y 36 de salida usando una función sigmoïdal como función de salida. Para clasificación del carácter se obtiene una secuencia de salidas que identifican una clase eligiendo la que tenga la salida máxima durante una última etapa de análisis estadístico. Esta etapa de análisis reduce el error en el proceso de clasificación causado por la similitud entre imágenes y el ruido en la imagen.

Deb et al. (2012) utilizan una red neuronal en la etapa de reconocimiento. La capa de entrada tiene 144 neuronas, 12×12 píxeles, y la capa de salida tiene 50 neuronas. Para la capa de entrada se

consideran los unos de la imagen como valores 0.5 y los ceros como -0.5. Para un carácter específico cada valor de la neurona de entrada es elevado al cuadrado y al final son sumados. Posteriormente se obtiene la inversa de la raíz cuadrada de dicha suma, la cual es llamada *factor de normalización*. Para una salida específica, cada valor de las neuronas de entrada es multiplicado por el peso aleatorio que conecta a la salida y los valores multiplicados son sumados. Esta suma es multiplicada por el factor de normalización. La neurona que tenga el valor mayor es seleccionada.

Los pesos de las neuronas de entrada que conectan con la neurona seleccionada son actualizados. El valor de la neurona de entrada es restado de la suma de los pesos aleatorios. El valor resultante es llamado *ajuste de pesos*. Entonces el factor de normalización es multiplicado por el ajuste de pesos y el valor resultante es sumado al peso aleatorio. Este proceso se repite para todos los caracteres. Finalmente se realiza un proceso de pre cálculo para buscar una neurona de salida diferente con el valor máximo para cada carácter de entrada; es decir, se obtiene el registro de la neurona con el valor máximo para cada carácter.

En el trabajo de Zhang & Wang (2012) los caracteres son normalizados a una proporción de 4×4 transformando cada línea de elementos a un vector de dimensión 16 el cual es la entrada a una red neuronal backpropagation. El número de elementos de salida es de 51 caracteres correspondientes a caracteres chinos, 25 letras mayúsculas y 10 dígitos.

Kocer & Cevik (2011) obtienen el vector característico usando el algoritmo de desviación del promedio absoluto, que se define como $V = \frac{1}{N}(\sum_N |f(x, y) - m|)$. Donde N es el número de pixels en la imagen, m es la media de la imagen y $f(x, y)$ es el valor en el punto (x, y) . En este trabajo las imágenes son divididas en sub imágenes de 4×5 pixeles para números y 5×5 para letras. Para el reconocimiento se utilizaron dos redes neuronales artificiales de tres capas.

Giannoukos et al. (2010) proponen un módulo de reconocimiento que consiste en dos redes neuronales artificiales, una para reconocimiento de números y otra para caracteres. La capa de entrada contiene 192 nodos los cuales corresponden al vector de entrada de 192 pixeles derivado de las dimensiones de los caracteres, 16×12 pixeles. Se usaron 367 plantillas de caracteres como conjunto de entrenamiento. La capa de entrada tiene 183 nodos para dígitos y 184 para caracteres. La capa de salida tiene 10 nodos para los caracteres y 14 nodos para letras.

3 Propuesta para el reconocimiento de matrículas empleando imágenes digitales

En esta sección se presenta la propuesta para extracción y reconocimiento de los caracteres de matrículas mexicanas. Como se menciona previamente, no todos los caracteres de las matrículas mexicanas pueden ser segmentadas empleando las técnicas comúnmente empleadas para este propósito debido a los patrones de textura del fondo. La extracción de caracteres que se propone es semejante al propuesto por Zhang & Zhang (2003), pero con menor costo computacional. Para el reconocimiento, los caracteres son modelados empleando los momentos de Hu (1962), los cuales han sido empleados exitosamente para clasificación de caracteres (Wong, Siu & Lam, 1995);

En la Figura 3.1 se muestra el diagrama de flujo del proceso del reconocimiento de placas. Se recibe una imagen de la placa; después se segmentan los caracteres y se extraen; los caracteres extraídos son modelados empleando algún método; los caracteres son clasificados y finalmente se obtienen los caracteres en ASCII.

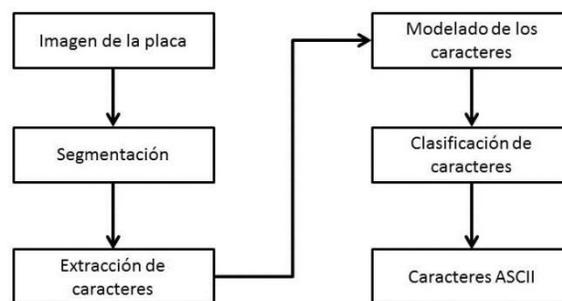


Figura 3.1. Diagrama de flujo del proceso de reconocimiento de placas.

De acuerdo a la Norma Oficial Mexicana NOM-001-SCT-2-2000 las placas de los vehículos mexicanos tienen un área de $30 \times 15 \text{ cm}^2$, la ubicación y dimensiones de los caracteres y otros componentes de las placas se establecen como se muestra en la Figura 3.2. Para mantener una escala proporcional a las dimensiones oficiales de la placa las imágenes adquiridas se normalizan a un tamaño de 300×150 píxeles. Es importante mencionar que en esta propuesta las imágenes de las

intensidades puede ser alto, dependiendo del tamaño de la imagen; con nuestra propuesta el costo computacional se reduce considerablemente porque calculamos el histograma acumulativo de intensidades, lo que implica que solo se cuentan las frecuencias de cada nivel de gris.

De los trabajos revisados que abordan el reconocimiento de matriculas de vehiculos, varios de ellos extraen los caracteres de la matricula empleando metodos basados en detección de bordes; luego las imágenes son binarizadas y finalmente los caracteres son extraidos empleando las proyecciones horizontal y vertical de perfiles. Por ejemplo, la Figura 3.3 muestra las imágenes binarizadas obtenidas al emplear dos tipos de procesamiento; (a), (d) imágenes de entrada, matriculas de los estados de Sinaloa y Durango, respectivamente; (b), (e) y (c), (f) son las imágenes obtenidas empleando las propuestas de Sedighi & Vafadust (2011) y Zheng et al. (2013), respectivamente.

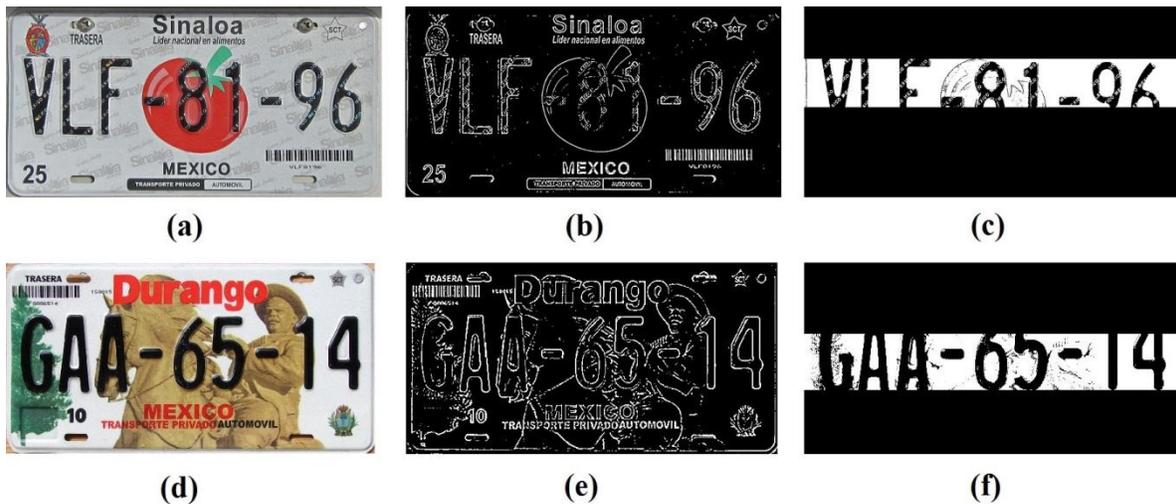


Figura 3.3. Ejemplo de imágenes obtenidas con diferentes enfoques de procesamiento: (a) y (b) imágenes de entrada; (b) y (e) imágenes obtenidas con el algoritmo propuesto por Sedighi and Vafadust (2011); (c) y (f) imágenes obtenidas usando la propuesta de Zheng et al. (2013).

Sedighi and Vafadust (2011) obtienen el laplaciano de los tres canales de color de la imagen, la imagen resultante es convertida a escala de grises y despues binarizada; los pixeles de los caracteres y de los objetos no deseados son 8-conectados en regiones de negro sobre fondo blanco, despues los caracteres candidatos son segmentados empleando características particulares.

Zheng et al. (2013) calculan los bordes verticales, la imagen que se obtiene es binarizada, las proyecciones vertical y horizontal se obtienen para establecer la altura y anchura de los caracteres, respectivamente. Los caracteres son extraidos por detección blob, que es un método extendido de etiquetado de pixeles que se basa en el analisis de componentes conectados. En ambos trabajos las imágenes son binarizadas con el método de Otsu (1979).

Notese que en la Figura 3.3 (b) y (e) los bordes de la textura del fondo también son detectados, lo que dificulta el cálculo de la altura y anchura de los caracteres; pero también no todos los caracteres pueden extraerse empleando conectividad de pixeles porque los caracteres pueden extraerse incompletos. En la Figura 3.3 (c) y (f) los caracteres son extraídos incompletos porque la altura de los caracteres no es calculada con precisión de la respectiva proyección de perfil vertical. Por lo tanto, los enfoques basados en detección de bordes no son adecuados para las matrículas mexicanas debido a los patrones de textura del fondo.

Sin embargo, como se menciona antes, aunque cada entidad federativa puede diseñar el fondo de sus matrículas, el tamaño y fuente de los caracteres deben cumplir las características que dicta la norma oficial Mexicana. De acuerdo a esta norma el porcentaje de área que ocupan los caracteres dentro de la matrícula es de hasta 20%. Las matrículas tienen seis caracteres para vehículos registrados en la Ciudad de México y siete caracteres para vehículos registrados fuera de la Ciudad de México; de aquí que la proporción de área que los caracteres ocupan dentro de la matrícula es ligeramente diferente, pero no significativa. La segmentación propuesta es la siguiente.

Sea I la imagen de entrada, la imagen es convertida a escala de grisis I_g . Para reducir los efectos de la iluminación no uniforme, a la imagen se le aplica un filtro Gaussiano H_g normalizado, el tamaño de la máscara es de 5×5 , esto es $I'_g = I_g * H_g$. Después, la imagen es procesada con el filtro de la mediana para eliminar o reducir el ruido e impurezas que pueda tener la matrícula; por lo tanto $I''_g = \text{mediana}(I'_g)$.

Se obtiene el histograma acumulativo $H_{cu}(k)$ de la imagen I''_g ; el histograma es normalizado al dividir sus valores entre el total de pixeles:

$$H_{cu}^*(k) = \frac{H_{cu}(k)}{N}, k = 0, 1, \dots, 255 \quad (3.1)$$

Donde N es el total de pixeles y k es el índice de la casilla del histograma. Buscamos el índice de la casilla para establecer el umbral para la binarización de la siguiente forma:

$$\delta = \min k \text{ tal que } H_{cu}^*(k) \geq 0.20, \text{ donde} \quad (3.2)$$

La imagen I''_g es binarizada con:

$$I_b(i, j) = \begin{cases} 1, & I''_g(i, j) \leq \delta \\ 0, & I''_g(i, j) > \delta \end{cases} \quad (3.3)$$



Figura 3.4. (a) y (b) imágenes obtenidas al asignar 1's al 20% de los pixeles con las intensidades más bajas y poniendo en 0 a los demás pixeles de las imágenes Figura 3.3 (a) y (d).

La imagen binaria I_b aun puede contener pixeles que son parte del fondo, para eliminarlos sin alterar los caracteres, la imagen binaria es erosionada. Esto es:

$$I_e = I_b \ominus H_e \quad (3.4)$$

Donde I_e es la imagen erosionada y \ominus denota el operador de erosión empleando la mascara H_e . La imagen I_e es dilatada para restaurar posibles caracteres *rotos* o incompletos:

$$I_d = I_e \oplus H_d \quad (3.5)$$

Donde I_d es la imagen dilatada y \oplus denota el operador de dilatación utilizando la mascara H_d . La mascara H_e y H_d tienen la forma de la Figura 3.5.

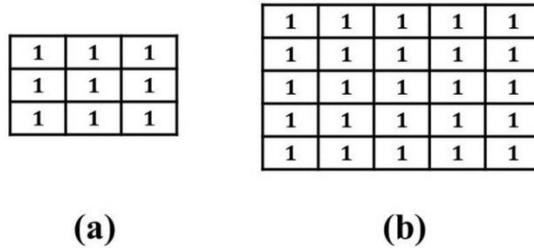


Figura 3.5. Mascaras (a) y (b) empleadas para las operaciones de erosión y dilatación, respectivamente.

Usualmente los caracteres se encuentran localizados, horizontalmente, en la mitad de la imagen; pero pueden existir objetos no deseados cerca de los bordes de la imagen. Con el fin de eliminar estos objetos no deseados o la mayoría de ellos la imagen es dividida en dos partes, una imagen superior y otra inferior. Se obtienen las proyecciones horizontales de ambas sub-imágenes; de la proyección de la sub-imagen superior se obtiene el índice más pequeño del valor más pequeño de la proyección, después todos los pixeles cuyo número de renglón sea menor a dicho índice se les asigna el valor de cero.

Análogamente, de la proyección horizontal de la sub-imagen inferior se obtiene el índice más pequeño del valor más pequeño de la proyección; después todos los pixeles cuyo número de renglón sea mayor a dicho índice se les asignan el valor de cero. Las imágenes resultantes y se juntan para formar la imagen I'_d , posteriormente los caracteres son extraídos y clasificados. En la Figura 3.6 (a)

y (c) se muestran las imágenes obtenidas después del proceso de erosión y dilatación de las imágenes de la Figura 3.4; en la Figura 3.6 (b) y (d) se muestran las imágenes obtenidas después de eliminar los objetos no deseados.

A pesar de que varios objetos no deseados son eliminados, aún quedan algunos objetos que pueden ser extraídos juntos con los caracteres. Para identificar si un objeto es un carácter o no, se calcula su proporción de área respecto al tamaño de la placa, considerando que los caracteres tienen un tamaño específico con respecto a la placa. El rango de valores aceptables se obtiene de forma experimental.

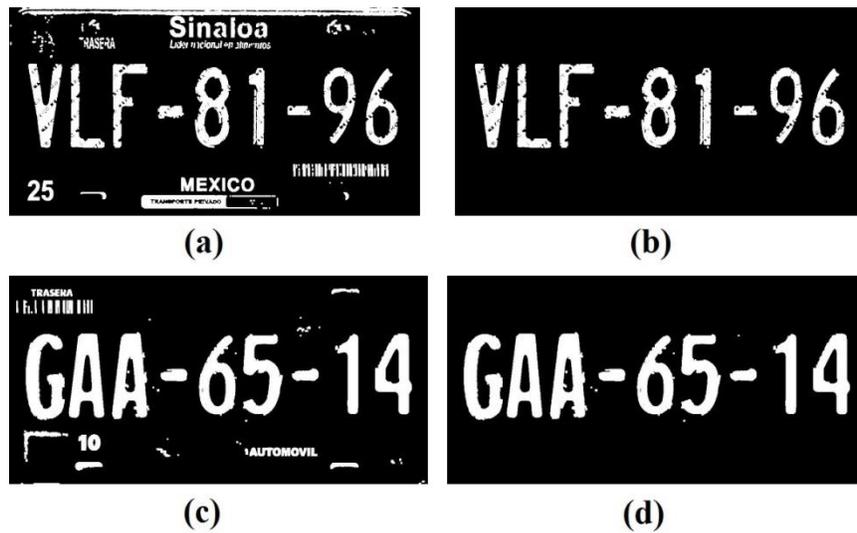


Figura 3.6. (a) y (c) imágenes obtenidas después de la erosión y dilatación de las imágenes de la Figura 3.4, (b) y (d) imágenes obtenidas después de eliminar objetos no deseados.

3.2 Modelado de los caracteres

Dentro de los métodos que comúnmente se emplean para modelar caracteres están los momentos de Hu (Hu, 1962). Para robustecer la caracterización de las letras, en este trabajo, se utilizan los descriptores de Fourier y algunas características geométricas básicas. Para extraer estas características, se construyen los conjuntos:

$$O_k = \{(x_1^k, y_1^k), \dots, (x_n^k, y_n^k)\} \quad (3.6)$$

Donde O_k es el conjunto cuyos elementos son las coordenadas de los pixeles que conforman el k -ésimo objeto segmentado. Con estos conjuntos se obtienen las características que se han mencionado.

3.2.1 Momentos de Hu

Los momentos de Hu son un conjunto de siete descriptores que permiten modelar un objeto, considerando la forma como una distribución de puntos 2D (Gonzalez & Woods, 2002). Se basa en los momentos centrales normalizados de la distribución de coordenadas, los cuales expresan parámetros característicos respecto al punto centroide. Sea $O = \{(x_1, y_1), \dots, (x_n, y_n)\}$ el conjunto de coordenadas de los píxeles de un objeto segmentado, los momentos de Hu se obtienen con:

$$\begin{aligned}
H_1 &= \eta_{20} + \eta_{02} \\
H_2 &= (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2 \\
H_3 &= (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \\
H_4 &= (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2 \\
H_5 &= (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \\
&\quad + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\
H_6 &= (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\
&\quad + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \\
H_7 &= (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \\
&\quad - (\eta_{30} - 3\eta_{12})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]
\end{aligned} \tag{3.7}$$

Los momentos centralizados y normalizados η_{pq} se obtienen con:

$$\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}^{c+1}} \tag{3.8}$$

Donde $c = (p + q)/2$. Los momentos centralizados se calculan con:

$$\mu_{pq}(O) = \sum_{(x,y) \in O} (x - \bar{x})^p (y - \bar{y})^q \tag{3.9}$$

Siendo (\bar{x}, \bar{y}) la coordenada del centroide del objeto, el cual se obtiene con:

$$\bar{x} = \frac{1}{n} \sum_{(x,y) \in O} x \tag{3.10}$$

$$\bar{y} = \frac{1}{n} \sum_{(x,y) \in O} y \tag{3.11}$$

3.2.2 Descriptores de Fourier

Los descriptores de Fourier consideran al conjunto de puntos que conforman el contorno de un objeto como una secuencia de números complejos, con los cuales se construye una función periódica unidimensional f que modela el contorno del objeto; los coeficientes de la transformada

de Fourier de la función f caracterizan el contorno de un objeto en el dominio de la frecuencia (Cuevas, Zaldívar & Pérez, 2010).

Sea $C \subset O$ el conjunto de las coordenadas de los píxeles del contorno de un objeto segmentado. Las coordenadas en

$$O = \{(x_0, y_0), \dots, (x_{M-1}, y_{M-1})\} \quad (3.12)$$

están indexadas de acuerdo a la secuencia en la que se encuentran ubicadas en el contorno en una dirección específica y que comienza en un punto arbitrario. Sea $f: C \rightarrow \mathbb{C}$ la función que transforma una coordenada en un número complejo como sigue:

$$f((x_k, y_k)) = x_k + iy_k \quad (3.13)$$

Donde $i = \sqrt{-1}$ y \mathbb{C} es el conjunto de números complejos. La transformada de Fourier de la función f se obtiene con:

$$F(u) = \frac{1}{M} \sum_{k=0}^{M-1} f((x_k, y_k)) \exp\left(\frac{-i2\pi uk}{M}\right) \quad (3.14)$$

A los coeficientes complejos $F(u)$ se les conoce como descriptores de Fourier del contorno. En este trabajo se obtienen 110 coeficientes, esto es, $F(u)$ es calculada para $u = 0, 1, \dots, 109$. Es importante señalar que tanto los descriptores de Fourier como los momentos de Hu son invariantes a los cambios de escala, posición y rotación de los objetos.

3.3 Clasificador Bayesiano

Para el reconocimiento de caracteres se implementa un clasificador Bayesiano; este clasificador estadístico se basa en el teorema de Bayes donde se asume que el vector de características tiene una distribución Gaussiana multivariable.

Sea $\{c_1, \dots, c_k\}$ el conjunto de k clases de caracteres, la probabilidad de que un carácter \mathbf{x} sea de la clase c_i se denota por $p(c_i|\mathbf{x})$. Del teorema de Bayes:

$$p(c_i|\mathbf{x}) = \frac{p(\mathbf{x}|c_i)p(c_i)}{p(\mathbf{x})} \quad (3.15)$$

Para la clasificación Bayesiana se escoge la clase c_i para la cual $p(\mathbf{x}|c_i)p(c_i)$ es el mayor. En otras palabras:

$$\arg \max_i p(\mathbf{x}|c_i)p(c_i) \quad (3.16)$$

De esta forma al carácter observado \mathbf{x} se le asigna la clase c_j . Asumimos que la distribución de probabilidad del vector de características del carácter observado \mathbf{x} , sea de clase c_j , es Gaussiana con media $\boldsymbol{\mu}_j$ y con matriz de covarianza $\boldsymbol{\Omega}_j$:

$$p(\mathbf{x}|c_j) = \frac{1}{\Delta} \exp \left[-\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu}_j)^T \boldsymbol{\Omega}_j^{-1} (\mathbf{x} - \boldsymbol{\mu}_j) \right] \quad (3.17)$$

Donde $\Delta = (2\pi)^{m/2} (\det \boldsymbol{\Omega}_j)^{1/2}$ y m es la dimensión de los vectores de características.

3.4 Análisis de Componentes Principales

Es una técnica que consiste en reducir la dimensionalidad del conjunto de datos. Los datos son proyectados a un subespacio de menor dimensión. Al considerar solo aquellas características de mayor valor se obtiene una reducción de dimensión sin perder precisión considerable. El subespacio se construye empleando como vectores base las componentes principales del conjunto de datos. Las componentes principales se obtienen como se describe a continuación:

1. Sea $\{\phi_1, \dots, \phi_m\} \subset \mathbb{R}^n$ un conjunto de vectores a los cuales se busca reducir su dimensión.
2. Se obtiene el vector promedio del conjunto con $\boldsymbol{\mu} = \frac{1}{m} \sum_{i=1}^m \phi_i$.
3. Se construye la matriz de covarianza $\boldsymbol{\Omega} = \frac{1}{m} \boldsymbol{\Phi} \boldsymbol{\Phi}^T$, donde $\boldsymbol{\Phi} = [\phi_1 - \boldsymbol{\mu}, \dots, \phi_m - \boldsymbol{\mu}]$.
4. Se obtienen los vectores propios de la matriz de covarianza $\lambda_1, \dots, \lambda_m$, los cuales son ordenados de forma descendente de acuerdo a su valor propio asociado y se colocan como vectores columna para formar la matriz $\boldsymbol{\Psi}$.

Los vectores propios que forman la matriz $\boldsymbol{\Psi}$ se les da el nombre de componentes principales, y forman el espacio propio. Una vez calculadas las componentes principales, se proyectan los vectores iniciales al espacio que forman las componentes principales de la siguiente forma:

$$\varphi_i = \boldsymbol{\Psi}^T (\phi_i - \boldsymbol{\mu}), i = 1, \dots, m \quad (3.18)$$

Se obtiene el conjunto de vectores $\{\varphi_1, \dots, \varphi_m\}$ que son la proyección al espacio propio de los vectores iniciales del conjunto $\{\phi_1, \dots, \phi_m\}$, que puede considerarse como el conjunto de entrenamiento. El efecto de emplear la ecuación \mathbf{x} es establecer un nuevo sistema de coordenadas cuyo origen quede en el centroide de la población y cuyos ejes estén en las direcciones de los vectores propios. Este sistema de coordenadas es una transformación de rotación que alinea los datos con los vectores propios. Este alineamiento es el mecanismo que descorrelaciona los datos.

Normalmente se escoge un subconjunto de vectores propios dependiendo de su respectivo valor propio, en donde los valores propios representan las varianzas de cada variable, de esta manera la cantidad de vectores propios que se seleccionan corresponde a la cantidad de valores propios cuya suma aporte una porcentaje significativo de la varianza total de los datos.

Para reconocer un nuevo valor observado θ , este se proyecta al espacio con:

$$\varphi_{\theta} = \mathbf{\Psi}^T(\theta - \mu) \quad (3.19)$$

La proyección obtenida φ_{θ} se compara con los vectores del conjunto de entrenamiento para asignarle una clase, lo cual en este trabajo se utiliza el clasificador Bayesiano que se ha mencionado anteriormente.

4 Experimentos y resultados

En esta sección se presentan los experimentos realizados y resultados obtenidos empleando 193 imágenes de placas de los 31 estados de la República Mexicana. Las imágenes fueron capturadas tal que la distancia entre la cámara y la placa fuera de entre 1.5 a 3 metros; además se procuró que la iluminación fuera uniforme. Las imágenes adquiridas son normalizadas a 300×150 píxeles. El 70% de las imágenes se emplearon para el entrenamiento y el resto se emplearon para realizar pruebas.

Es importante mencionar que no se hicieron pruebas con placas de vehículos del Distrito Federal ya que estas tienen seis caracteres mientras que las placas de los automóviles de los Estados tienen siete caracteres. Esta característica, si bien no afecta en la segmentación de los caracteres, si repercute en la fase de extracción de los caracteres ya que es necesario establecer o fijar la cantidad de objetos que se obtienen de la placa una vez binarizada.

A continuación se presentan las pruebas en dos partes:

1. Se muestran los resultados obtenidos en el reconocimiento de caracteres; aquí se presenta cuáles son los caracteres que son mejor clasificados así como los que son más difíciles de reconocer.
2. Se presentan la tasa de porcentaje de reconocimiento de las placas de los diferentes Estados; esto es, que se hayan reconocido exitosamente todos los caracteres de cada placa.

4.1 Pruebas de reconocimiento de caracteres

Para las pruebas de reconocimiento de caracteres se utilizó un total de 1467 caracteres. En la **Tabla 4.1** se muestra la cantidad de elementos que conforman cada conjunto de cada clase de caracteres.

Como se menciona anteriormente, los caracteres son modelados con los siete momentos de Hu y con 110 descriptores de Fourier. De aquí que la dimensión del vector de características es de 117. La cantidad de descriptores se determinó de manera experimental. El 70% de las muestras se emplean para el entrenamiento, el resto se utiliza para realizar pruebas.

Tabla 4.1. Total de muestras por clase de carácter para las pruebas de reconocimiento

Carácter	No. de muestras
0	53
1	81
2	68
3	58
4	65
5	78
6	81
7	92
8	74
9	87
A	33
B	15
C	18
D	30
E	26
F	34
G	35
H	29
J	31
K	15
L	18
M	17
N	11
P	27
R	24
S	15
T	21
U	32
V	38
W	24
X	28
Y	26
Z	31

La Tabla 4.2 muestra las tasas de reconocimiento obtenidos de cada clase de carácter y el promedio de reconocimiento.

Tabla 4.2. Resultados de identificación de caracteres con el 30% de datos de prueba

Carácter	No. de muestras	Muestras identificadas	Porcentaje
0	15	15	100.00
1	23	23	100.00
2	19	19	100.00
3	16	16	100.00
4	18	18	100.00
5	22	22	100.00
6	23	11	47.83
7	27	27	100.00
8	21	20	95.24
9	25	13	52.00
A	9	8	88.89
B	3	2	66.67
C	4	4	100.00
D	8	7	87.50
E	7	6	85.71
F	9	9	100.00
G	9	9	100.00
H	8	8	100.00
J	8	8	100.00
K	3	3	100.00
L	4	2	50.00
M	4	3	75.00
N	2	1	50.00
P	7	6	85.71
R	6	6	100.00
S	3	3	100.00
T	5	5	100.00
U	9	9	100.00
V	10	10	100.00
W	6	5	83.33
X	7	7	100.00
Y	7	7	100.00
Z	8	8	100.00
Total:	355	320	
		Promedio:	89.94

Como se puede observar en la Tabla 4.2, los porcentajes más bajos de reconocimiento se dan en los caracteres 6 y 9 los cuales se confunden entre sí, ya que estrictamente hablando el 6 es un 9 rotado 180° y viceversa. Debido a que tanto los descriptores de Fourier como los momentos de Hu son invariantes a la rotación, ambos caracteres son modelados como si fueran los mismos.

Por otra parte el carácter L se confunde con el 7, se puede ver fácilmente que estos caracteres tienen una apariencia similar si son rotados 180°; en algunos casos el carácter N se confunde con el carácter K. El carácter B con se confunde con el número 8. El porcentaje promedio de reconocimiento es del 89.94%.

Con el objetivo de reducir el costo computacional a causa de la dimensión de los vectores de características, se utiliza análisis de componentes principales para reducir la dimensionalidad. La cantidad de componentes se selecciona en la cantidad de valores propios cuya suma acumule el 95% del total de la suma de los valores propios, es decir, el 95% de la varianza que contienen los valores propios y en consecuencia sus respectivos vectores propios. De aquí que se seleccionan cinco componentes principales y en consecuencia la dimensión de los vectores de características se reduce de dimensión 117 a 5.

En la Tabla 4.3 se muestran los resultados obtenidos del reconocimiento de caracteres al reducir la dimensionalidad de los vectores de características utilizando componentes principales. Se puede ver claramente que el reconocimiento se redujo demasiado, obteniendo un promedio de 28.23% de reconocimiento, lo que implica que la reducción de componentes no sea un procedimiento adecuado para este propósito.

Es importante mencionar que los caracteres I, O y Q no se emplean en las placas vehiculares mexicanas debido a que así lo especifica la norma NOM-001-SCT-2-2000.

Tabla 4.3. Resultados de identificación de caracteres aplicando componentes principales al conjunto de datos

Carácter	No. de muestras	Muestras identificadas	Porcentaje
0	15	2	13.33
1	23	17	73.91
2	19	4	21.05
3	16	8	50.00
4	18	0	0.00
5	22	17	77.27
6	23	0	0.00
7	27	13	48.15
8	21	10	47.62
9	25	11	44.00
A	9	5	55.56
B	3	0	0.00
C	4	0	0.00
D	8	3	37.50
E	7	1	14.29
F	9	5	55.56
G	9	5	55.56
H	8	0	0.00
J	8	3	37.50
K	3	0	0.00
L	4	1	25.00
M	4	1	25.00
N	2	0	0.00
P	7	0	0.00
R	6	0	0.00
S	3	0	0.00
T	5	3	60.00
U	9	8	88.89
V	10	1	10.00
W	6	4	66.67
X	7	0	0.00
Y	7	0	0.00
Z	8	2	25.00
Total:	355	124	
		Promedio:	28.23

4.2 Pruebas de reconocimiento de matrículas

De la sección 4.1 se ha observado que es posible obtener un reconocimiento relativamente alto de los caracteres extraídos.

Tabla 4.4. Resultados de identificación de placas por Estado

Estado	No. de muestras	Muestras Reconocidas	Porcentaje
Aguascalientes	3	3	100.00
Baja California	11	7	63.64
Baja California Sur	4	0	0.00
Campeche	3	2	66.67
Chihuahua	7	5	71.43
Colima	3	1	33.33
Coahuila	10	3	30.00
Chiapas	3	1	33.33
Durango	9	5	55.56
Estado de México	5	2	40.00
Guerrero	5	3	60.00
Guanajuato	6	3	50.00
Hidalgo	6	3	50.00
Jalisco	12	7	58.33
Michoacán	5	4	80.00
Morelos	5	4	80.00
Nuevo León	8	7	87.50
Nayarit	8	0	0.00
Oaxaca	5	1	20.00
Puebla	7	6	85.71
Quintana Roo	5	3	60.00
Querétaro	7	4	57.14
Sinaloa	5	3	60.00
Sonora	8	2	25.00
San Luis Potosí	8	2	25.00
Tabasco	2	0	0.00
Tamaulipas	10	5	50.00
Tlaxcala	6	1	16.67
Veracruz	5	3	60.00
Yucatán	3	1	33.33
Zacatecas	9	6	66.67
Total:	193	97	
		Promedio:	49.01

Pero el reconocimiento de matrículas conlleva reconocer los seis caracteres que conforman la matrícula. En estas pruebas, una matrícula se dice que es reconocida si los seis caracteres son clasificados exitosamente. Si un carácter o más no son bien clasificados entonces se considera que la matrícula no es reconocida exitosamente. En la Tabla 4.4 se muestran los resultados obtenidos de las placas por cada estado. Prácticamente, en promedio, se reconocieron la mitad de las placas con el 49.01%, aunque es importante mencionar que varias de las placas no se reconocieron exitosamente debido a que faltó reconocer solo un carácter.

Algunos de los factores que influyen negativamente en el reconocimiento de las placas son que los caracteres no son oscuros, la intensidad de los tonos de los patrones de textura del fondo son bajos y/o caracteres con marca de agua, ver Figura 4.1. En la sección 0 se analizan estos factores.

Aunque el porcentaje de clasificación de caracteres es muy bajo empleando componentes principales, se decidió emplear la reducción de dimensionalidad para el reconocimiento de placas. Los resultados obtenidos se presentan en la Tabla 4.5. El porcentaje de reconocimiento es muy bajo, obteniendo solo el 0.46%, esto debido a que como previamente se vio en la sección 4.1, al reducir la dimensionalidad de los vectores de características, se pierde precisión.



(a)



(b)



(c)

Figura 4.1 (c) Casos especiales que dificultaron la segmentación de los caracteres. a) Placa con caracteres claros. b) Placa con colores de fondo oscuros. c) Caracteres con marca de agua.

Tabla 4.5. Resultados de identificación de placas por Estado utilizando componentes principales

Estado	No. de muestras	Reconocidas	Porcentaje
Aguascalientes	3	0	0.00
Baja California	11	0	0.00
Baja California Sur	4	0	0.00
Campeche	3	0	0.00
Chihuahua	7	0	0.00
Colima	3	0	0.00
Coahuila	10	0	0.00
Chiapas	3	0	0.00
Durango	9	0	0.00
Estado de México	5	0	0.00
Guerrero	5	0	0.00
Guanajuato	6	0	0.00
Hidalgo	6	0	0.00
Jalisco	12	0	0.00
Michoacán	5	0	0.00
Morelos	5	0	0.00
Nuevo León	8	0	0.00
Nayarit	8	0	0.00
Oaxaca	5	0	0.00
Puebla	7	0	0.00
Quintana Roo	5	0	0.00
Querétaro	7	1	14.29
Sinaloa	5	0	0.00
Sonora	8	0	0.00
San Luis Potosí	8	0	0.00
Tabasco	2	0	0.00
Tamaulipas	10	0	0.00
Tlaxcala	6	0	0.00
Veracruz	5	0	0.00
Yucatán	3	0	0.00
Zacatecas	9	0	0.00
Total:	193	1	
		Promedio:	0.46

En la siguiente sección 0 se discuten los resultados obtenidos.

5 Discusión de resultados

De los resultados obtenidos se observa que si bien el porcentaje de clasificación de los caracteres se puede considerar como aceptable, hasta cierto punto, el porcentaje reconocimiento de las placas es bajo. Es importante mencionar que el reconocimiento de una placa se considera como exitoso si todos los caracteres de la placa son clasificados correctamente; es decir, si un carácter de los siete es clasificado erróneamente, a pesar de que los otros seis se clasifiquen exitosamente, implica que la placa no es reconocida.

Esto no necesariamente significa que nuestra propuesta sea deficiente; sin embargo, es necesario analizar cuáles son factores que afectan negativamente en el reconocimiento de las placas. Dentro de los factores que se han observado que influyen en la clasificación de los caracteres son:

1. Patrones de textura complejos y marcas de agua en los caracteres.
2. Cambios en la iluminación.

A continuación se analizan de qué forma afectaron estos factores en los experimentos realizados.

5.1 Patrones de textura complejos y marcas de agua en los caracteres

Como se menciona previamente, la principal dificultad de las placas de vehículos mexicanos es que tienen patrones de textura en el fondo. Por lo que las técnicas y algoritmos que se encuentran en los trabajos previos no siempre funcionan porque en estas técnicas y algoritmos se asume que las placas no tienen patrones de textura en el fondo. La mayoría están diseñados asumiendo que las placas son de fondo blanco, sin ningún patrón de textura, y con caracteres de color negro.

El patrón de textura del fondo de las placas mexicanas es diferente dependiendo del Estado. Es decir, cada Estado puede diseñar su propio patrón de textura de fondo, lo que implica que puedan existir hasta 31 diseños. Por otra parte, cada Estado por lo general en determinados intervalos de tiempo, ordena el re-emplacamiento de los vehículos registrados en su entidad. Pero no siempre todos los vehículos les son actualizadas sus placas, debido a diferentes factores; por

ejemplo: cambio de residencia o simplemente incumplimiento por parte de los dueños de los automóviles.

Esto conlleva a que de un Estado existan vehículos portando placas con más de un tipo de patrón de textura en el fondo. Por ejemplo, en la Figura 5.1 (a) y (b) se muestran dos placas del Estado de Jalisco, pero en ambas se tienen diferentes patrones de textura en el fondo. En la Figura 5.1 (c) y (d) también se presentan dos placas del Estado de Sinaloa, en donde ambas tienen diferentes patrones de textura en el fondo.



(a)



(b)



(c)



(d)

Figura 5.1. Placas de vehículos mexicanos pertenecientes al mismo Estado pero con diferentes diseños. (a) y (b) placas del Estado de Jalisco; (c) y (d) placas del Estado de Sinaloa.

La segmentación de los caracteres, hasta cierto punto, no es tan difícil ya que como se ha mencionado, la segmentación es posible gracias a que se emplean las características de las dimensiones que deben cumplir los caracteres de acuerdo a la NOM-001-SCT-2-2000. Por lo que los diferentes fondos de las placas influyen poco, aunque si los patrones de textura del fondo tienen colores oscuros, estos pueden influir negativamente en la segmentación.

Por ejemplo, en la Figura 5.2 se muestra una placa vehicular del Estado de Tlaxcala. Esta placa es una de las más difíciles de reconocer debido a que en los extremos se encuentran dos figuras con colores oscuros. Al momento de segmentar, los caracteres de las orillas no se extraen

correctamente. El porcentaje de reconocimiento de placas del Estado de Tlaxcala es uno de los más bajos, como se ve en la Tabla 4.4.



Figura 5.2. Placa vehicular del Estado de Tlaxcala

Otro de los factores que dificultan la extracción de los caracteres son las marcas de agua que en ocasiones tienen las letras. Por ejemplo, en la Figura 5.3 se muestran placas de algunos Estados en donde los caracteres tienen impresos marcas de agua.



Figura 5.3. Placas con marcas de agua en los caracteres

Estas marcas de agua ocasiona que los caracteres sean extraídos incompletos o *rotos*, también muchas veces los caracteres se extraen con *hoyos* aunque estos no afectan tanto como el hecho de que los caracteres sean segmentados incompletos. Dado que los descriptores de Fourier modelan la forma de los caracteres, al estar incompleto una letra, su caracterización se vuelve imprecisa; pero los hoyos al estar dentro del carácter no repercuten significativamente.

La caracterización con los momentos de Hu también se vuelve imprecisa si las letras son extraídas incompletas o con hoyos. Con esta caracterización también se modela la forma de las letras por lo que al tener estos detalles los caracteres el modelado no es suficiente para lograr una clasificación exitosa.

5.2 Iluminación no uniforme

Otro factor que influye en el reconocimiento de la placa es la intensidad de la iluminación de la placa. Dado que para segmentar los caracteres, las imágenes de las placas se binarizan al tomar los píxeles con las intensidades más bajas, las cuales corresponden a los caracteres. Pero si la placa no es iluminada uniformemente o si la iluminación es muy intensa, tal que hasta produzca destellos, entonces la segmentación falla. En la Figura 5.4 se muestran imágenes de placas con iluminación no uniforme.



Figura 5.4. Imágenes de placas de vehículos con iluminación no uniforme

Como se puede ver en la Figura 5.4, estas placas tienen destellos, algunas partes más oscuras que otras. Esto provoca que las letras no tengan la misma intensidad y en consecuencia la segmentación se vuelve imprecisa al no extraer las letras completamente o que incluso no segmente letras completas.

Tanto la iluminación no uniforme como las marcas de agua son temas que deben abordarse como trabajos futuros, ya que como se ha mostrado, influyen en la segmentación exitosa de los caracteres.

6 Conclusiones y trabajo futuro

Se ha presentado una propuesta para el reconocimiento de placas de vehículos mexicanos empleando visión artificial. El método propuesto aborda dos fases: 1) segmentación de caracteres y 2) clasificación de caracteres. La segmentación de caracteres consiste en obtener el 20% de los píxeles con las intensidades más bajas, ya que estos son los píxeles que corresponden a los caracteres. Por otra parte, este porcentaje se establece siguiendo los criterios de fabricación de las placas de la norma NOM-001-SCT-2-2000. De acuerdo a las dimensiones establecidas para la placa y de sus letras, el porcentaje de la suma de las áreas de los caracteres con respecto al de toda la placa es del 20%.

La clasificación de caracteres, primero estos son modelados empleando los momentos de Hu y los descriptores de Fourier, en donde se emplearon 110 descriptores. Se utilizó un clasificador Bayesiano para el reconocimiento de los caracteres. En los experimentos realizados se observa que el porcentaje de clasificación de los caracteres es relativamente alto, con el 89.94% de un conjunto de 355 caracteres. El reconocimiento de las placas tiene un porcentaje bajo de reconocimiento del 49.01% de un conjunto de 193 placas de diferentes Estados. Es importante mencionar que el reconocimiento de la placa involucra reconocer todas las letras de la placa; por lo que con tan solo clasificar erróneamente un solo carácter implica que la placa no sea reconocida correctamente, y consecuencia se calcule la baja eficiencia del reconocimiento.

Se observa que la clasificación de caracteres disminuye significativamente si se reduce la dimensionalidad a los vectores de características empleando componentes principales. De aquí que se recomienda no reducir la dimensionalidad con esta técnica.

La segmentación de los caracteres es la parte más importante en el proceso del reconocimiento de las placas, ya que si los caracteres no son extraídos correctamente, el modelado es impreciso y se producen los errores de clasificación. Dentro de los problemas que ocasionan que los caracteres no sean segmentados adecuadamente, y que deben abordarse como trabajo futuro, son:

- Iluminación no uniforme: se observó que los caracteres no se extraen adecuadamente cuando la placa tiene una iluminación muy intensa o si en esta tiene partes con

diferentes intensidades. Es necesario diseñar una técnica que reduzca los efectos negativos de la iluminación no uniforme.

- Marcas de agua en los caracteres: como se había mencionado anteriormente, en algunas placas, sus caracteres tienen marcas de agua lo que dificulta la segmentación de la letra. Estas suelen ser extraídas con *hoyos* o incompletas, lo que conlleva a que el modelado de los caracteres sea impreciso y en consecuencia un error de clasificación.
- El color de los caracteres de las placas es usualmente negro, pero existen placas en donde sus caracteres tienen colores diferentes al negro. Esto dificulta la segmentación ya que pueden tener intensidades altas. Es necesario abordar en el futuro los casos de placas cuyos caracteres son de color diferente al negro.

Referencias

- Anagnostopoulos, C. N., Anagnostopoulos, I., Loumos, V., & Kayafas, E. (2006). A license plate-recognition algorithm for intelligent transportation system applications. *IEEE Transactions on Intelligent Transportation Systems*, 7(3), 377-392.
- Cuevas, E., Zaldívar, D., & Pérez Cisneros, M. (2010). *Procesamiento Digital de Imágenes con Matlab y Simulink*. México, D.F.: Alfaomega Grupo Editor.
- Deb, K., Khan, I. M., Saha, A., & Jo, K.-H. (2012). An Efficient Method of Vehicle Licence Plate Recognition Based on Sliding Concentric Windows and Artificial Neural Network. *Procedia Technology*, 4, 812-819.
- Du, S., Ibrahim, M., Shehata, M., & Badawy, W. (2013). Automatic License Plate Recognition (ALPR): A State of Art Review. *IEEE Transactions on Circuits and Systems for Video Technology*, 23(2), 311-325.
- Faqheri, W. A., & Mashohor, S. (2009). A real-time Malaysian automatic license plate recognition (M-ALPR) using hybrid fuzzy. *International Journal of Computer Science and Network Security*, 9(2), 333-340.
- Gazcón, N. F., Chesnevar, C. I., & Castro, M. S. (2012). Automatic vehicle identification for Argentinean license plates using intelligent template matching. *Pattern Recognition Letters*, 33(9), 1066-1074.
- Giannoukos, I., Anagnostopoulos, C.-N., Loumos, V., & Kayafas, E. (2010). Operator context scanning to support high segmentation rates for real time license plate recognition. *Pattern Recognition*, 43(11), 3866-3878.
- Gonzalez, R. C., & Woods, R. E. (2002). *Digital Image Processing*. Pearson.
- Hu, M. (1962). Visual pattern recognition by moment invariant. *IRE Transactions on Information Theory*, 179-187.
- Jiao, J., Ye, Q., & Huang, Q. (2009). A configurable method for multi-style plate recognition. *Pattern Recognition*, 42, 358-369.

- Kocer, H. E., & Cevik, K. K. (2011). Artificial neural networks based vehicle licence plate recognition. *Precedia Computer Science*, 3, 1033-1037.
- Mai, V., Miao, D., Wang, R., & Zhang, H. (2011). An improved method for Vietnam license plate location. *International Conference on Computational and Information Sciences*, pp. 212-215.
- Martinsky, O. (2007). *Algorithmic and Mathematical Principles of Automatic Number Plate Recognition Systems*. BRNO University of Technology.
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man and Cybernetics*, SMC-9(1), 62-66.
- Pan, M. S., Yan, J. B., & Xiao, Z. H. (2008). Vehicle license plate character segmentation. *International Journal of Automation and Computing*, 5(4), 425-432.
- Pan, X., Ye, X., & Zhang, S. (2005). A hybrid method for robust car plate character recognition. *Engineering Applications of Artificial Intelligence*, 18(8), 963-972.
- Pratt, W.K., (2001). *Digital Image Processing* (third ed.). John Wiley & Sons, Inc.
- Russ, J. C. (2011). *The Image Processing Handbook*. Boca Raton, FL: CRC Press.
- Sedighi, A., & Vafadust, M. (2011). A new and robust method for character segmentation and recognition in license plate images. *Expert Systems with Applications*, 38(11), 13497-13504.
- Shapiro, V., Gluhchev, G., & Dimov, D. (2006). Towards a multinational car license plate recognition system. *Machine Vision and Applications*, 17(3), 173-183.
- Siddique, N. A., Iqbal, A., Mahmud, F., & Rahman, S. (2012). Development of an automatic vehicle license plate detection and recognition system for Bangladesh. *International Conference on Informatics, Electronics and Vision*, pp. 688-693.
- Tian, Y., Yap, K. H., & He, Y. (2012). Vehicle license plate super-resolution using soft learning prior. *Multimedia Tools and Applications*, 60(3), 519-535.
- Wang, F., Man, L., Wang, B., Xiao, Y., Pan, W., & Lu, X. (2008). Fuzzy-based algorithm for color recognition of license plates. *Pattern Recognition Letters*, 29(7), 1007-1020.

- Wong, W. H., Siu, W. C., & Lam, K. M. (1995). Generation of moment invariants and their uses for character recognition. *Pattern Recognition Letters*, 16(2), 115-123.
- Zhang, Y., & Zhang, C. (2003). A new algorithm for character segmentation of license plate. *Intelligent Vehicles Symposium. Proceedings. IEEE*, pp. 106-109.
- Zhang, Z., & Wang, C. (2012). The research of Vehicle Plate Recognition Technical Based on BP Neural Network. *AASRI Procedia*, 1, 78-81.
- Zheng, L., He, X., Samali, B., & Yang, L. (2013). An algorithm for accuracy enhancement of license plate recognition. *Journal of Computer and System Sciences*, 79(2), 245-255.
- Zhu, Y., Huang, H., Xu, Z., He, Y., & Liu, S. (2011). Chinese-style Plate Recognition Based on Artificial Neural Networks and Statistics. *Procedia Engineering*, 15, 3556-3561.

Apéndice A

Tabla A.1 Imágenes de las placas actuales de los 32 Estados mexicanos

Estado	Imagen	Estado	Imagen
Aguascalientes		Morelos	
Baja California		Nuevo Leon	
Baja California Sur		Nayarit	
Campeche		Oaxaca	
Chihuahua		Puebla	
Colima		Quintana Roo	
Coahuila		Queretaro	
Chiapas		Sinaloa	

Mexico City		Sonora	
Durango		San Luis Potosi	
Estado de México		Tabasco	
Guerrero		Tamaulipas	
Guanajuato		Tlaxcala	
Hidalgo		Veracruz	
Jalisco		Yucatan	
Michoacán		Zacatecas	



Josue E. Espinoza M. <jeespinoza.mx@gmail.com>

[IA] Envío recibido

1 mensaje

Miguel A. Salido <editor@iberamia.org>

8 de diciembre de 2015, 1:58

Para: Josue Erick Espinoza Morales <jeespinoza.mx@gmail.com>

Josue Erick Espinoza Morales:

Gracias por enviarnos su manuscrito "Reconocimiento Automático de Matriculas de Automóviles Particulares Mexicanos" a Iberoamerican Journal of Artificial Intelligence. Gracias al sistema de gestión de revistas online que usamos podrá seguir su progreso a través del proceso editorial identificándose en el sitio web de la revista:

URL del manuscrito:

<http://polar.lsi.uned.es/revista/index.php/ia/author/submission/1128>

Nombre de usuario/o: jeespinozamx

Si tiene cualquier pregunta no dude en contactar con nosotros/as. Gracias por tener en cuenta esta revista para difundir su trabajo.

Miguel A. Salido

Iberoamerican Journal of Artificial Intelligence

IBERORAMERICAN JOURNAL OF ARTIFICIAL INTELLIGENCE

<http://journal.iberamia.org/>



Descripción/Description/Descrição



La revista 'Inteligencia Artificial', Revista Iberoamericana de I.A. pretende ser un foro abierto de presentación e intercambio de noticias, actividades, experiencias, desarrollos, proyectos, resúmenes, etc.; así como para la publicación de artículos científico-técnicos de calidad relevante sobre las diferentes áreas de la Inteligencia Artificial y realizados preferentemente en el entorno español e iberoamericano. Además de los contenidos previos, la revista también publica monografías específicas sobre áreas concretas de la IA. El ámbito preferente de interés es el contexto España e Iberoamericano. Por ello, el objetivo final es configurar una publicación de referencia sobre la Inteligencia Artificial en este contexto. Con todo ello, se pretende establecer un medio que permita una mayor intercomunicación, expansión y publicación de resultados entre los equipos de investigación y/o desarrollo de España e Iberoamérica, que permita su mayor conocimiento mutuo y potenciación. Adicionalmente, se pretende potenciar el desarrollo de las diferentes áreas de la IA y un mayor conocimiento de la misma en las diferentes Universidades y Centros de Investigación y Desarrollo. A fin de conseguir una mayor expansión y acceso a la publicación, su contenido es libremente accesible por internet. Adicionalmente, la revista es también publicada mediante su edición convencional en papel.

En catálogo.

Características cumplidas/Cumpridas/Standards met: 26

Características no cumplidas/Não cumpridos/Standards not met: 7

Folio	13056
Acopio	España
Fecha de Alta	2005-10-27
Fecha de Modificación	2013-03-05
Tipo de Registro	Modificado
Título	Inteligencia Artificial. Revista Iberoamericana de Inteligencia Artificial
Título Abreviado	Intel. artif.
País	España
Situación	Dejó de publicarse
Año Inicio	1997
Año Terminación	2009
Frecuencia	Trimestral
Tipo de Publicación	Publicación periódica
Soporte	Impreso en papel
Idioma(s)	Español Inglés
ISSN	1137-3601
Temas	Inteligencia artificial-robótica
Clasificación Decimal Universal	007.52
Organismo Responsable	Facultad de Informática, Universidad Politécnica de Valencia
Editorial	Asociación Española para la Inteligencia Artificial
Responsables	Lawrence Mandow
Calle	Camino de Vera s/n
Ciudad	Valencia
Estado/Provincia/Departamento	Comunidad Valenciana
País Editor	España
Código Postal	46022
Email	revista@aepia.org
Teléfonos	(34) 96-3877000 ext. 77768
Fax	(34) 96-3877209
Indizada/Resumida en	DIALNET Directory of Open Access Journals (DOAJ) e-Revistas ICYT Latindex-Catálogo Latindex-Directorio Red ALyC Scopus
Naturaleza de la Publicación	Revista de investigación científica
Naturaleza de la Organización	Asociación científica o profesional
Notas	Dejó de publicarse en versión impresa. ISSN electrónico 1988-3064