

UNIVERSIDAD DE CANTABRIA

DEPARTAMENTO DE TECNOLOGÍA ELECTRÓNICA,
INGENIERÍA DE SISTEMAS Y AUTOMÁTICA



TESIS DOCTORAL

DETECCIÓN Y LOCALIZACIÓN DE
VEHÍCULOS MEDIANTE SOMBRAS
EN LA CARRETERA BASADA EN
VISIÓN POR COMPUTADOR

MANUEL IBARRA ARENADO
INGENIERO INDUSTRIAL

2016

UNIVERSIDAD DE CANTABRIA

ESCUELA TÉCNICA SUPERIOR DE INGENIEROS
INDUSTRIALES Y DE TELECOMUNICACIÓN

DEPARTAMENTO DE TECNOLOGÍA ELECTRÓNICA,
INGENIERÍA DE SISTEMAS Y AUTOMÁTICA



DETECCIÓN Y LOCALIZACIÓN DE
VEHÍCULOS MEDIANTE SOMBRAS
EN LA CARRETERA BASADA EN
VISIÓN POR COMPUTADOR

MEMORIA
presentada para optar al grado de
DOCTOR POR LA UNIVERSIDAD DE CANTABRIA
Manuel Ibarra Arenado

EL DIRECTOR

Dr. Juan M. Pérez Oria

Catedrático de Ingeniería de Sistemas y Automática

Universidad de Cantabria

Santander, enero de 2016

A mis padres

Agradecimientos

Me gustaría expresar mi más sincero agradecimiento a:

- Dr. Juan M. Pérez Oria, mi director de tesis, por su apoyo, motivación y buenos consejos durante la realización de esta tesis.
- a mis compañeros del Grupo de Ingeniería de Control por todos los consejos y la ayuda prestada.
- al Programa Nacional para la Formación de Personal Investigador (FPI) del Ministerio de Economía y Competitividad.
- Dr. Tardi Tjahjadi por su ayuda y por haberme dado la oportunidad de trabajar bajo su supervisión en la School of Engineering de la Universidad de Warwick, Coventry, Reino Unido.
- a Ivo y a Fran por su amistad.
- a Andrés, Azucena, Bárbara, Chisco, Cos, David, Gustavo, Juancar, Laura, Susana, Teresa y Zoraida por ser los mejores amigos.
- a mis padres Manuel y Manuela, a mis hermanas Ana e Isabel y a mi sobrina Ana porque son lo que más quiero en el mundo.

Índice de Figuras

1.1 Ejemplos de la detección de vehículos precedentes en la trayectoria en típicas escenas de tráfico urbano y bajo diversas condiciones metereológicas	7
1.2 Ejemplos de la detección de bordes de sombra.....	8
2.1 Ejemplos de la sombra bajo el vehículo. (a) día nublado, (b) día soleado, (c) día soleado pero con el vehículo circulando por una región sombreada de la carretera y (d) día lluvioso.....	31
2.2 Detección de los bordes generados por las sombras bajo los vehículos en función de la distancia. (Arriba) imagen adquirida, (centro) imagen en escala de grises (colorjet para una mejor apreciación de las transiciones de intensidad) y (abajo) mapa de bordes obtenido mediante el operador Sobel.	35
2.3 Ejemplos de típicas escenas de tráfico urbano en días nublados, (a) región de búsqueda, (b) gradientes de intensidad verticales $M(x,y)$, (c) máscara binaria $M(x,y)$ tras la aplicación de las condiciones de saturación e intensidad, (d) $M(x,y)$ tras la umbralización por intensidad, (e) $M(x,y)$ tras la extracción de gradientes adyacentes debidos a sombras laterales, (f) grupos horizontales de gradientes de $M(x,y)$, (g) $M(x,y)$ tras filtrado morfológico y establecimiento de la ROI y (h) hipótesis finales incluídas aquellas fuera de la ROI.	38
2.4 Ejemplos de típicas escenas de tráfico urbano en días soleados. (a) región de búsqueda, (b) gradientes de intensidad verticales $M(x,y)$, (c) máscara binaria $M(x,y)$ tras la aplicación de las condiciones de saturación e intensidad, (d) $M(x,y)$ tras la umbralización por intensidad, (e) $M(x,y)$ tras la extracción de gradientes adyacentes debidos a sombras laterales, (f)	

grupos horizontales de gradientes de $M(x,y)$, (g) $M(x,y)$ tras filtrado morfológico y establecimiento de la ROI y (h) hipótesis finales incluídas aquellas fuera de la ROI.....	39
2.5 Escenas bajo diferente iluminación y asfalto. Las gráficas representan la variación de las componentes RGB (roja, verde, azul) y la saturación IHLS (negro) desde un punto de la carretera iluminada por la luz ambiental P_r hasta un punto en la región bajo el vehículo P_s (región acromática).	43
2.6 Umbralizado por intensidad del conjunto de gradientes bajo el vehículo de la Fig. 2.4 izquierda. (a) Imagen inicial, (b) conjunto de gradientes debidos a la sombra bajo el vehículo y a la sombra lateral, (c) Intensidad de los píxels superiores del conjunto y (d) conjunto de gradientes resultante tras aplicar el segundo umbral.	52
2.7 Variación de la anchura del vehículo V_{width} con respecto a su posición vertical en la imagen x.	54
2.8 Hipótesis generadas a partir de los ejemplos de las Figs. 2.3 y 2.4.	56
2.9 Ejemplos de los resultados de la generación de hipótesis incluídas aquellas fuera de la ROI.....	57
2.10 Ejemplos de las hipótesis generadas obtenidas. (a) hipótesis positivas, (b) hipótesis de vehículos incorrectamente enmarcados y (c) falsos positivos correspondientes a no vehículos o vehículos fuera de los objetivos del sistema.	58
2.11 Escena en día nublado: (a) región de búsqueda, (b) su histograma de grises. Columna izquierda (método propuesto en [46]): (c) mapa de bordes, (e) espacio libre de conducción, (g) histograma del área libre de conducción y (i) mapa de bordes tras el umbralizado de intensidad. Columna derecha (método propuesto): (d) gradiente de intensidad vertical, (f) $M(x,y)$ tras la aplicación de las condiciones de saturación e intensidad, (h) histograma	

del conjunto de píxeles superiores de los gradientes y (j) $M(x,y)$ tras el umbralizado de intensidad.	60
2.12 Escena en día soleado: (a) región de búsqueda, (b) su histograma de grises. Columna izquierda (método propuesto en [46]): (c) mapa de bordes, (e) espacio libre de conducción, (g) histograma del área libre de conducción y (i) mapa de bordes tras el umbralizado de intensidad. Columna derecha (método propuesto): (d) gradiente de intensidad vertical, (f) $M(x,y)$ tras la aplicación de las condiciones de saturación e intensidad, (h) histograma del conjunto de píxeles superiores de los gradientes y (j) $M(x,y)$ tras el umbralizado de intensidad.	63
2.13 Hipótesis de vehículo: (a) hipótesis, (b) bordes verticales, (c) bordes horizontales, (d) puntos de simetría de intensidad y (e) eje de simetría Y_S	68
3.1 Variación en la imagen de la distancia del vehículo respecto a su posición vertical en la imagen SVP	80
3.2 Curva que relaciona la distancia del vehículo $Dist$ y su posición vertical en la imagen SVP	81
4.1 Iluminación en exteriores: componentes RGB de (a) la luz del cielo ($I_{Rsky}, I_{Gsky}, I_{Bsky}$), (b) la luz del sol ($I_{Rsun}, I_{Gsun}, I_{Bsun}$), y (c) una región no sombreada.	97
4.2 Distribuciones RGB de una superficie acromática debidas a la luz del cielo (a), y a la luz del sol (b).	104
4.3 Penumbra: (a) Umbra S_u , penumbra desde S_{pl} hasta S_{pn} y región no sombreada S_{n-s} , y (b) toda la región sombreada causada por un elemento delgado está en penumbra, ya que todos los puntos están parcialmente iluminados por la luz del sol.	106
4.4 Dos escenas en presencia de sombras: (a) imagen original, (b) mapa de	

bordes obtenido mediante el operador Canny y las correspondientes componentes normalizadas (c) azul y (d) roja.....	107
4.5 Región de la carretera compuesta por asfalto no sombreado, umbras y penumbras. A lo largo de la penumbra: (b) componentes roja y verde respecto a la azul, (c) componentes normalizadas <i>rgb</i> y (d) saturación. .	109
4.6 Ejemplos de los resultados del método. Para cada ejemplo, (arriba) imagen original, (Medio) su mapa de bordes, y (abajo) el mapa de bordes resultante tras detectar y eliminar los bordes de sombra.....	118
4.7 Ejemplo: (a) Imágen original, (b) mapa de bordes, (c) “ground truth” de los bordes de sombra y (d) “ground truth” de los bordes debidos a un cambio de material.....	120
4.8 Mapas de bordes resultantes tras aplicar los cinco métodos. (a) <i>A1</i> método, (b) <i>A2</i> método, (c) <i>A3</i> método, (d) <i>A4</i> método y (e) el método método.....	122

Índice de Tablas

2.1 Resultados de la generación de hipótesis	59
2.2 Resultados de la verificación de hipótesis	72
2.3 Resultados del sistema de detección de vehículos.....	73
3.1 Calibración de la medida <i>Dist-SVP</i>	81
4.1 Selección de los píxeles a ambos lados del borde $C_I(x,y)$	115
4.2 Análisis cuantitativo	123

Índice General

1. INTRODUCCIÓN.....	1
1.1 Motivación y alcance	1
1.2 Planteamiento del problema.....	6
1.3 Desafíos de la detección de vehículos	7
1.4 Resumen de los métodos propuestos	10
1.5 Organización de la tesis.....	13
2. DETECCIÓN DE VEHÍCULOS	17
2.1 Introducción	17
2.2 Generación de Hipótesis	18
2.2.1 Introducción.....	18
2.2.2 Estado del Arte	19
2.2.2.1 Métodos basados en apariencia del vehículo	19
2.2.2.2 Métodos basados en estereovisión.....	25
2.2.2.3 Métodos basados en el movimiento.....	27
2.2.3 Sombra bajo el vehículo. Fundamentos.....	29
2.2.4 Método propuesto: Generación de Hipótesis.....	36
2.2.4.1 Introducción.....	36
2.2.4.2 Región de búsqueda en la imagen	37
2.2.4.3 Gradientes verticales de intensidad	37
2.2.4.4 Umbralización por intensidad.....	48
2.2.4.5 Filtrado morfológico.....	52
2.2.4.6 Región de interés, ROI.....	55
2.2.4.7 Resultados.....	55
2.3 Verificación de Hipótesis	64
2.3.1 Introducción.....	64
2.3.2 Estado del Arte	64

2.3.3 Método propuesto	67
2.3.3.1 Introducción	67
2.3.3.2 Bordes horizontales y verticales	67
2.3.3.3 Simetría.....	69
2.3.3.4 Resultados.....	72
2.4 Conclusiones	74
3. CÁLCULO DE LA DISTANCIA.....	77
3.1 Introducción y estado del arte particular	77
3.2 Estimación de la distancia	79
3.3 Conclusiones	82
4. DETECCIÓN DE SOMBRAS.....	85
4.1 Introducción	85
4.2 Estado del arte.....	87
4.3 Fundamentos físicos de las sombras: modelo de reflexión de la luz....	91
4.4 Distribución espectral de la iluminación y de las sombras.....	96
4.4.1 Iluminación y características de las sombras	96
4.4.2 Características de las sombras propuestas	99
4.4.3 Descripción de la penumbra. Características propuestas...	105
4.4.4 Identificación de los bordes de las sombras.....	112
4.5 Algoritmo de clasificación de los bordes de las sombras	114
4.6 Resultados	116
4.7 Conclusiones	124
5. CONCLUSIONES Y TRABAJO FUTURO.....	127
5.1 Conclusiones	127
5.2 Contribuciones	132
5.3 Trabajo Futuro.....	133
Referencias.....	135

Capítulo 1

INTRODUCCIÓN

1.1 Motivación y alcance

La seguridad en la carretera es actualmente uno de los campos de investigación que más interés despiertan en la industria del automóvil. Aproximadamente cada año muere en el mundo 1,3 millones de personas en accidentes de tráfico y se estima que entre 20 y 50 millones sufren daños o lesiones importantes [1]. La actual tendencia indica un incremento en la tasa de accidentalidad del 65%, lo que convertirá a los accidentes de tráfico en la quinta causa de mortalidad en el año 2030 [1]. Esta preocupante cifra motivó que en el año 2011 Naciones Unidas lanzara un programa global para la seguridad en la carretera "Decade of Action for Road Safety 2011-2020" [2]. El objetivo de este plan es frenar la tasa de siniestralidad y una de las principales iniciativas del programa consiste en promover el uso de tecnologías que ayuden a evitar o al menos reducir el número de accidentes.

Una de las principales herramientas de las que se dispone son los Sistemas de Ayuda a la Conducción (ADAS, *Advanced Driver Assistance Systems*), los cuales alertan al conductor de una situación de riesgo en la carretera y si no hay reacción por parte de éste, asisten en última instancia de forma activa con el fin de evitar el accidente. Los sistemas ADAS entran así a formar parte de la seguridad activa del vehículo cuyo máximo objetivo es la prevención de accidentes.

El interés por los sistemas ADAS comenzó hace ya más de dos décadas y en la actualidad estos sistemas están en pleno auge, siendo cada vez más numerosos. Los fabricantes, centros de investigación y universidades están realizando grandes esfuerzos en perfeccionar y desarrollar nuevos sistemas de ayuda a la conducción con el objetivo de lograr no solo vehículos más seguros, sino también más energéticamente eficientes y confortables. Existe una gran variedad de sistemas ADAS, algunos de los cuales están ya plenamente asentados en el mercado como el Sistema Antibloqueo de Frenos (ABS), el Sistema Electrónico de Asistencia a la Frenada (EBS), el Sistema de Control Electrónico de Estabilidad (ESC) o el Sistema de Control de Velocidad de Crucero Adaptativo (ACC). Otros en cambio, están aún en pleno desarrollo y se van introduciendo progresivamente, como el Sistema Anticolisión Frontal (FCAS), el Sistema de Aviso de Salida de Carril (LDW), el Sistema de Detección de Peatones con Frenada de Emergencia (AEBS), el Sistema de Reconocimiento de Señales de Tráfico (TSRS), el Sistema de Ayuda al Aparcamiento (APS), etc.

El presente trabajo de Tesis Doctoral se centra en el desarrollo de un sistema de detección de vehículos en la trayectoria que entre a formar parte de un Sistema Anticolisión Frontal para tráfico urbano. El objetivo de los sistemas FCAS (*Forward Collision Avoidance System*) es ayudar al conductor

a mantener una adecuada distancia de seguridad con el vehículo que le precede en su trayectoria, para así evitar o al menos reducir el número y la severidad de las colisiones del tipo Frontal-Trasera. Desgraciadamente, la distancia de seguridad entre vehículos no se mantiene en muchos casos, bien por negligencia o bien por distracción y especialmente en las ciudades, donde uno de los principales tipos de accidente son las colisiones entre vehículos. Ante una insuficiente distancia de seguridad, los sistemas FCAS alertan al conductor mediante una señal sonora y/o visual, y si éste no reacciona, algunos sistemas actúan autónomamente. Bien disminuyendo la velocidad del vehículo, bien preparando los Airbags o bien tensando los cinturones de seguridad.

El modo de operación de los sistemas FCAS consiste en tres fases principales: 1) percepción del entorno del vehículo mediante diferentes tipos de sensores (detección de vehículos y cálculo de distancias), 2) identificación de situaciones de riesgo y 3) suministro de la información al conductor. Detectar y calcular la distancia del vehículo precedente en la trayectoria es por lo tanto, una fase fundamental y es la que presenta una mayor complejidad. De ella depende el correcto funcionamiento del sistema, por lo que su fiabilidad, precisión y capacidad de operación en tiempo real son requisitos esenciales.

Diferentes tipos de sensores pueden ser empleados para detectar el vehículo precedente en la trayectoria, siendo los sistemas basados en sensores radar y laser (LIDAR, *Light Detection and Ranging*) los más asentados en el mercado. La mayor ventaja de estos sensores es su capacidad para detectar objetos y medir directamente las distancias sin necesidad de un alto coste computacional, lo que hace factible el funcionamiento del sistema en tiempo real. Son además robustos ante variaciones medioambientales

(lluvia, viento) e independientes de la iluminación, pudiendo operar correctamente tanto de día como de noche. La fiabilidad de la detección y distancia proporcionada por el LIDAR en condiciones de lluvia densa y niebla es muy baja. Aunque son dos los principales inconvenientes tanto del radar como del LIDAR. En primer lugar, se trata de sensores activos, lo que puede ocasionar interferencias entre vehículos que lleven incorporado el mismo sistema y circulen simultáneamente en el mismo tramo de la carretera. En segundo lugar, su elevado coste económico hace que la incorporación en el mercado de sistemas basados en estas dos tecnologías se limite únicamente a vehículos de alta gama.

Los sensores ópticos (cámaras) y la visión por computador han atraído una gran atención en la última década y en la actualidad son uno de los segmentos que más rápidamente están creciendo dentro de los sistemas ADAS. Las altas prestaciones de las cámaras actuales, el incremento en la capacidad y velocidad de las unidades de procesado, los avances en los campos del procesado de imagen y vision por computador, y su bajo coste en comparación con los sensores radar y LIDAR, hacen de los sensores ópticos y de la visión por computador la gran alternativa de futuro. A esto hay que añadir que los sensores ópticos son sensores pasivos, quedando exentos de los problemas de interferencia propios de los sensores activos. Sin embargo, la mayor ventaja de los sensores ópticos radica sin duda, en que la información visual es la ayuda más valiosa para la identificación tanto del entorno del vehículo como de los potenciales riesgos de accidente. La visión por computador es una tecnología versátil, capaz de extraer diferente información de la escena de la carretera como la detallada forma de los objetos (vehículos, peatones, señales de tráfico), las líneas de carril, etc, lo cual genera una gran ventaja respecto a las tecnologías radar y láser.

Sin embargo, la visión por computador presenta una serie de dificultades que hacen de ella uno de los campos de investigación más activos dentro de los sistemas FCAS. En primer lugar, requieren de complicados algoritmos de procesamiento de imagen para extraer la información de la escena, lo que supone un alto coste computacional que condiciona la capacidad de funcionamiento en tiempo real. En segundo lugar, los sensores ópticos se ven altamente afectados por las condiciones atmosféricas, dificultando el funcionamiento en condiciones de niebla densa, lluvia torrencial y de noche sin una iluminación adecuada. El funcionamiento de los sistemas FCAS basados en visión se reduce a condiciones meteorológicas que permitan una correcta apreciación visual del entorno como días soleados, nublados, lluvia no torrencial, niebla poco densa, nevadas suaves, etc. En estas condiciones, la ayuda de la visión por computador resulta valiosísima en casos de imprudencia, distracción o adormecimiento del conductor. En tercer y último lugar, los sistemas FCAS operan en exteriores, estando fuertemente condicionados por la iluminación, la cual es desconocida (día soleado, nublado, etc.), cambiante de un frame al siguiente e incontrolable.

En el presente trabajo de Tesis Doctoral se propone una alternativa tanto para la detección de los vehículos en la trayectoria, como para el cálculo de su distancia por medio de un único sensor óptico y técnicas de visión por computador. Hasta la fecha, la falta de trabajos que aborden el cálculo de distancias mediante una única cámara, hace de esta tarea fundamental un desafío importante [3]. Además, el método propuesto está específicamente diseñado para operar en tráfico urbano, donde uno de los tipos de accidente más frecuentes que se dan son las colisiones entre vehículos del tipo Frontal-Trasera.

Por otro lado, se presenta un método para la detección de sombras en la carretera. Las sombras son un fenómeno consecuencia de la iluminación de la escena, y en la image pueden modificar la forma y el color de la superficie donde se proyectan, introduciendo una distorsión que dificulta considerablemente el proceso tanto de detección de vehículos, líneas de carril y peatones, como el proceso de segmentación de la carretera. Por esta razón, la identificación de sombras en la escena es una etapa importante en el procesado de imagen, la cual se viene estudiando desde hace décadas.

1.2 Planteamiento del problema

El presente trabajo de Tesis Doctoral se centra en el desarrollo de un sistema de detección de vehículos en la trayectoria basado en visión por computador que entre a formar parte de un Sistema Anticolisión Frontal para tráfico urbano.

El objetivo es detectar y calcular la distancia a la que se encuentran los vehículos que preceden al vehículo en el que está instalado el sistema (ego-vehículo) a partir de las imágenes adquiridas por una cámara (ver Fig. 1.1). La cámara se encuentra instalada junto al espejo retrovisor con el fin de obtener la mejor perspectiva de la región de la carretera enfrente del ego-vehículo.

En segundo lugar, se aborda el estudio de la detección de sombras causadas por la luz ambiental en exteriores, las cuales suponen un desafío bien conocido para los sistemas ADAS basados en visión por computador. Se propone un método de detección de sombras en la carretera basado en las propiedades cromáticas de las mismas.




Figura 1.1: Ejemplos de la detección de vehículos precedentes en la trayectoria en típicas escenas de tráfico urbano y bajo diversas condiciones metereológicas.

El objetivo es, una vez calculado el mapa de bordes de la imagen adquirida, identificar y eliminar los bordes originados por los límites de las sombras (ver Fig. 1.2). De este modo, se consigue un mapa de bordes formado únicamente por los bordes debidos a un cambio de material, es decir, los bordes generados por los objetos de la escena como los vehículos, líneas de carril, bordillos, etc.

1.3 Desafíos de la detección de vehículos

La detección de vehículos basada en visión por computador para sistemas FCAS, supone un enorme desafío. Aunque muchas técnicas y métodos han sido propuestos hasta la fecha, todavía supone un campo de investigación plenamente activo, donde los esfuerzos se dirigen a lograr sistemas más fiables, más precisos y más rápidos.




Figura 1.2: Ejemplos de la detección de bordes de sombra.

Son diversos los factores que dificultan la detección de vehículos en una imagen. En primer lugar, el proceso de detección no se puede reducir a la búsqueda en la imagen de un vehículo con unas características únicas. El tamaño, la forma y el color de los vehículos varía en función de la marca y del modelo, por lo que el procedimiento de detección se ha de ampliar a la búsqueda de ciertas características o patrones comunes a todos los modelos (ver Fig. 1.1). Por otro lado, los vehículos pueden aparecer en la imagen en muy diversas poses (frontal, lateral, trasera, etc). El desarrollo de un sistema capaz de identificar un vehículo independientemente de su pose es muy complejo, por lo que los métodos de detección de vehículos para sistemas FCAS se limitan únicamente a la detección de la trasera de los vehículos.

Otro factor que dificulta considerablemente la detección de los vehículos son los escenarios de carretera desconocidos y cambiantes (ver Fig. 1.1). Al no tener conocimiento a priori de la escena, ninguna consideración previa acerca de la misma puede ser realizada. En los sistemas FCAS, el ego-vehículo está

en constante movimiento, por lo que el escenario de la carretera está constantemente cambiando. De este modo, el fondo de la imagen varía de un frame al siguiente, por lo que no pueden ser empleadas técnicas como la sustracción del fondo de imagen, la cual es comúnmente utilizada para la detección de vehículos en aplicaciones con cámara fija.

Por otro lado, los escenarios de la carretera propios de los entornos urbanos presentan dificultades añadidas para los sistemas basados en visión por computador, como fondos de imagen repletos de objetos (edificios, aceras, bordillos, árboles, farolas, peatones, etc.) y carreteras saturadas de indicaciones en el asfalto (líneas de carril, pasos de cebra, señalizaciones de dirección y de ceda el paso, etc) (ver Fig. 1.1). Todos estos elementos interfieren con el vehículo precedente en la trayectoria, dificultando su reconocimiento en la imagen y haciendo necesario el uso de complicados algoritmos para extraer la información de la escena. Esto además, contribuye en intensificar otro gran inconveniente en los sistemas FCAS y sistemas ADAS en general, que es la elevada carga computacional que conlleva el procesamiento de imagen, el cual condiciona considerablemente la capacidad de operar en tiempo real, requisito indispensable en los sistemas FCAS.

Existen otros factores que condicionan la detección de vehículos, como las vibraciones propias del ego-vehículo en movimiento inducidas a la cámara o como la oclusión parcial de los vehículos por otros elementos de la escena, pero sin duda, uno de los principales problemas a los que se enfrentan los sistemas FCAS basados en visión por computador es la iluminación. Los sistemas FCAS operan en exteriores, por lo que la iluminación es desconocida e incontrolable (ver Fig. 1.1). Uno de los mayores problemas que origina la iluminación son las sombras proyectadas tanto en la carretera como en los objetos de la escena, las cuales pueden ocasionar la unión aparente entre los

distintos elementos, así como alterar sus características de intensidad, cromaticidad e incluso forma. Las sombras proyectadas en la carretera son un fenómeno indeseable para toda clase de sistemas ADAS basados en visión por computador, ya que dificultan tareas esenciales como la segmentación de la carretera y la detección de vehículos, peatones y líneas de carríl.

Por otro lado, un gran inconveniente aparece a la hora de calcular la distancia a la que se encuentra el vehículo detectado. Los sistemas monoculares (sistemas compuestos por una sola cámara), no son capaces de proporcionar de una manera precisa la distancia a la que se encuentran los objetos de la escena (vehículo precedente), siendo los sistemas basados en estereovisión (sistemas compuestos de dos cámaras), los únicos capaces de obtener información de la profundidad de los objetos de la imagen. El principal inconveniente de la estereovisión es que conlleva un enorme coste computacional. Además, precisa de constantes procesos de calibración (las vibraciones del vehículo en movimiento provocan fácilmente el descalibrado de las cámaras).

El objetivo del presente trabajo de Tesis Doctoral es extender el actual conocimiento y contribuir con el desarrollo de diversos métodos tanto para la detección de vehículos como para la detección y eliminación de las sombras en la imagen.

1.4 Resumen de los métodos propuestos

Detección de vehículos

En primer lugar se presenta un sistema monocular para detectar el vehículo que nos precede en la trayectoria y estimar la distancia a la que se

encuentra respecto del ego-vehículo. El método de detección de vehículos propuesto se divide en dos etapas: generación de hipótesis GH y verificación de hipótesis VH.

Las hipótesis son generadas de acuerdo con la región sombreada de la carretera debajo del vehículo. Se propone una estrategia nueva para la detección de la sombra del vehículo que es una alternativa a los métodos existentes en el estado del arte y que supera importantes dificultades como la presencia de sombras laterales en la carretera.

El método en el que se ha trabajado se centra inicialmente en distinguir entre las transiciones de intensidad de la imagen originadas por la sombra bajo los vehículos de aquellas producidas por otros elementos de la escena. Para ello se comparan las propiedades cromáticas de los píxeles de la imagen a ambos lados de las transiciones de intensidad. A partir del conjunto formado por los píxeles superiores de las transiciones de intensidad resultantes y en base al hecho de que la sombra bajo un vehículo es una región de la carretera muy oscura, se establece un umbral de intensidad. De este modo, las regiones con menor intensidad que el umbral son candidatas a ser la sombra bajo un vehículo.

Para cada candidato a ser sombra bajo un vehículo, un refinado umbral de intensidad es aplicado para descartar posibles sombras adyacentes proyectadas lateralmente por los elementos de la imagen. Finalmente, tras un filtrado morfológico en base al conocimiento previo de la pose y tamaño de las traseras de los vehículos, se establece una región de interés ROI, la cual abarca el área de la carretera enfrente del ego-vehículo. Únicamente los vehículos precedentes circulando dentro de la ROI son susceptibles a una colisión del tipo Frontal-Trasera con el ego-vehículo, por lo que solamente los candidatos a sombra localizados dentro de la ROI son considerados hipótesis

generadas definitivas.

Un hecho significativo es que el método propuesto opera correctamente para las diversas condiciones de iluminación de la escena, para todo tipo de asfalto e independientemente de la distancia existente entre el vehículo precedente y el ego-vehículo, proporcionando una elevada tasa de detección de hipótesis verdaderas.

La estrategia de verificación de hipótesis presentada, está basada en la evaluación de características de la apariencia comunes a todas las traseras de los vehículos. Los candidatos a vehículo son verificados usando una combinación de tres características: bordes horizontales, verticales y simetría de la trasera del vehículo. Un candidato a vehículo ha de satisfacer las tres condiciones para ser finalmente verificado como tal.

Cáculo de la distancia

Para todas aquellas hipótesis verificadas como vehículo, se calcula la distancia a la que se encuentran respecto del ego-vehículo. La medición de la distancia de un objeto mediante una única cámara se puede realizar de dos formas, 1) conociendo el plano de superficie (carretera) de la imagen, y 2) mediante una vista frontal y conociendo la verdadera magnitud del objeto. Ambas formas requieren una calibración previa del sistema.

Las dimensiones de los vehículos son diferentes en función de la marca y modelo por lo que son desconocidas. Sin embargo, la sombra bajo un vehículo se puede considerar como su proyección vertical sobre la superficie.

El método propuesto para calcular la distancia del vehículo precedente se basa en la localización vertical en la imagen de la sombra bajo el mismo y en la asunción de carretera plana. La estimación de la distancia es directa, a

partir de la relación previamente obtenida entre la posición vertical de la sombra en la imagen y la distancia real a la que se encuentra el vehículo (proceso de calibrado previo del sistema).

Detección de bordes de sombra en la carretera

En la segunda parte de este trabajo de Tesis, se presenta un método para la detección de los bordes de las sombras proyectadas en la carretera basado en propiedades físicas tanto de la iluminación como de la superficie. El método no requiere calibración de la cámara y considera dos fuentes de iluminación con distintas distribuciones espectrales: la luz del sol y la luz del cielo. Como los sistemas ADAS basados en visión se caracterizan por escenas con fondos dinámicos de imagen, el método propuesto se centra en distinguir entre los bordes de las sombras y los bordes causados por un cambio de material mediante la comparación de píxeles a ambos lados de los bordes de la imagen. El método propuesto aborda separadamente las umbras (sombras) y las penumbras mediante la observación de sus diferentes propiedades espectrales. Para las umbras, se explotan algunas observaciones acerca de la cromaticidad de las sombras, y se presentan tres nuevas observaciones en base a la contribución de la luz del sol en la cromaticidad de la superficie. Además, se describe la variación no lineal de la cromaticidad en la penumbra y se plantea un método para clasificar bordes delimitando umbras, penumbras y regiones de la carretera no sombreadas.

1.5 Organización de la tesis

El resto de capítulos de esta Tesis Doctoral están organizados de acuerdo con el resumen presentado en la Sección 1.4 de la presente introducción.

En el Capítulo 2 se presenta la detección de vehículos basada en visión por computador. El capítulo se divide en dos secciones principales. La Sección 2.2 se centra en la generación de hipótesis de vehículo, en la cual se comienza repasando los trabajos más relevantes del estado del arte que abordan esta etapa fundamental (Sección 2.2.2). En la Sección 2.2.3 se exponen detenidamente los fundamentos y el estado del arte particular de las sombras bajo los vehículos como característica para la detección de los mismos. La Sección 2.2.4 pasa a describir detalladamente el método propuesto para la detección de la sombra y se muestran además los resultados obtenidos. La Sección 2.3 se centra en la fase de verificación de hipótesis, la cual comienza con un repaso de los principales enfoques del estado del arte que abordan esta tarea (Sección 2.3.2). En la Sección 2.3.3 se detalla el método propuesto para la verificación de candidatos así como se muestran los resultados obtenidos (sección 2.2.3).

En el Capítulo 3, el método desarrollado para el cálculo de la distancia entre el vehículo precedente y el ego-vehículo es presentado. Comienza con un introducción donde se expone la problemática para calcular distancias con una única cámara (Sección 3.1) y pasa a describir el método propuesto en la Sección 3.2. En la Sección 3.3 se presentan las conclusiones.

En el Capítulo 4 se aborda el método desarrollado para la detección de sombras en la carretera. En la Sección 4.2 se repasan las estrategias más relevantes del estado del arte y en la Sección 4.3 se exponen los fundamentos físicos de las sombras, donde se presenta el modelo de reflexión de la luz en el que nos basamos. La sección 4.4 pasa a describir la distribución espectral de la iluminación y su efecto en las superficies. En esta sección se presentan nuevas condiciones que satisfacen los bordes de las sombras, y se describen las penumbras. El algoritmo de clasificación de los bordes de las sombras se

presenta en la sección 4.5 y finalmente se cierra el Capítulo mostrando los resultados obtenidos (Sección 4.5).

Finalmente, en el Capítulo 5 se enumeran las conclusiones alcanzadas durante la elaboración de la tesis, así como las aportaciones de la misma al estado del arte. También se da una visión de los trabajos futuros a realizar.

Capítulo 2

DETECCIÓN DE VEHÍCULOS

2.1 Introducción

Los sistemas de detección del vehículo precedente en la trayectoria generalmente emplean una o dos cámaras montadas en el ego-vehículo. La cámara suele situarse en el interior del mismo, en una posición lo más elevada posible (generalmente junto al espejo retrovisor) con el fin de obtener la mejor perspectiva de la región de la carretera enfrente del ego-vehículo.

La detección de los vehículos en la imagen consiste en buscar a lo largo y ancho de la misma, uno o varios patrones comunes a todos los vehículos, independientemente de las características particulares de cada marca y modelo. Esta tarea conlleva unos altos requisitos computacionales, por lo que con fin de minimizar el proceso, la detección de vehículos se suele realizar en dos etapas [4]: generación de hipótesis (HG, *Hypotheses Generation*) y verificación de hipótesis (HV, *Hypotheses Verification*).

En la generación de hipótesis, las regiones de la imagen que potencialmente contienen un vehículo son identificadas mediante un análisis rápido de toda la imagen. La verificación de hipótesis consiste en cambio, en un análisis más profundo de las regiones de la imagen contenidas en las hipótesis proporcionadas, reduciendo así la carga computacional.

En el presente Capítulo se aborda tanto la generación como la verificación de hipótesis. La Sección 2.2 se centra en la etapa de generación de hipótesis mientras que la Sección 2.3 aborda la verificación de las mismas.

2.2 Generación de Hipótesis

2.2.1 Introducción

El propósito de la generación de hipótesis consiste en un análisis de toda la imagen con el fin de encontrar posibles regiones que contengan un vehículo. Existe un gran número de métodos de generación de hipótesis, los cuales se pueden clasificar en tres categorías principales [4]: 1) métodos basados en la apariencia del vehículo, 2) métodos basados en estereovisión y 3) métodos basados en el movimiento.

Los métodos basados en la apariencia del vehículo analizan la imagen con el fin de encontrar características morfológicas de los vehículos que los diferencien de otros objetos de la escena. Esos métodos están muy condicionados tanto por la iluminación como por los fondos de imagen saturados de elementos. Los métodos basados en estereovisión pueden explotar tanto el mapa de disparidad (DM, *Disparity Map*) como el mapa de perspectiva inversa (IPM, *Inverse Perspective Mapping*), ambos generados a partir de las dos imágenes (imagen izquierda y derecha). Estos métodos

implican la búsqueda de correspondencias entre ambas imágenes, lo cual es una tarea compleja que conlleva un largo tiempo de procesamiento. Finalmente, los métodos basados en el movimiento requieren el análisis de una secuencia de imágenes para detectar los objetos en movimiento, lo cual se realiza a partir de su flujo óptico. El flujo óptico se obtiene emparejando píxeles de imágenes consecutivas, lo que supone una elevada carga computacional. Los métodos basados en el movimiento requieren del análisis de varias imágenes para detectar un vehículo.

2.2.2 Estado del Arte

2.2.2.1 Métodos basados en apariencia del vehículo

Los métodos basados en la apariencia hacen uso de características morfológicas comunes a todos los vehículos independientemente de la marca y del modelo [5-9]. Los vehículos además, pueden aparecer en la imagen en diversas poses. Encontrar una característica morfológica común a un mismo vehículo para todas las poses es muy complejo, por lo que los métodos de detección de vehículos para sistemas FCAS se limitan únicamente a la detección de la trasera de los mismos. La perspectiva que se tiene de los vehículos precedentes circulando en el mismo carril es trasera, sin embargo, el perfil de aquellos vehículos aparcados o circulando en carriles paralelos puede aparecer en la imagen (sobre todo si circulan a poca distancia del ego-vehículo). El perfil lateral de estos vehículos puede llegar a distorsionarse en la imagen la trasera del vehículo (el contorno del vehículo, la simetría, etc).

Los métodos basados en la apariencia están muy condicionados tanto por la iluminación, como por los fondos saturados de objetos. Las principales

características empleadas por estos métodos son descritas a continuación:

Simetría

Las traseras de los vehículos se caracterizan por ser simétricas respecto a un eje central vertical, por lo que localizando en la imagen regiones con una elevada simetría vertical es posible detectar potenciales vehículos. Esta observación ha sido usada como característica particular para la detección de vehículos en diversos trabajos [10]. En general, esta técnica emplea un operador de simetría en una región dada de la imagen. La simetría puede ser de intensidad, de color, del contorno de la trasera o de los bordes horizontales. En [11], se propone un método para calcular un eje vertical de simetría a partir de un operador de simetría de intensidad de la trasera, donde el marco (bounding box) que contiene el vehículo se estima mediante la detección de pares de bordes simétricos respecto a dicho eje vertical. En [12], se presenta un método que explota tres tipos de simetrías de las traseras de los vehículos: simetría del contorno, simetría de intensidad y simetría de los bordes horizontales.

La simetría es una característica bastante fiable para la detección de vehículos, sin embargo, cuando se emplea en la fase de generación de hipótesis supone una elevada carga computacional. Por este motivo algunos trabajos proponen el empleo de esta característica en la fase de verificación de hipótesis, donde sólo pequeñas regiones de la imagen necesitan ser analizadas [12]. Como inconveniente podemos señalar que para que las traseras de los vehículos satisfagan la condición de simetría, éstas deben ser observadas perpendicularmente al plano de las mismas. En curvas cerradas, el plano en el que se encuentra la trasera del vehículo precedente no es exactamente paralelo al plano de la imagen, por lo que la fiabilidad de la

característica de simetría disminuye. Por otro lado, en el escenario de la carretera pueden aparecer otros elementos con elevados valores de simetría como regiones de la imagen pertenecientes al asfalto o al cielo. Por lo tanto, la simetría no es fiable por sí sola y requiere ser combinada con otras características de las traseras de los vehículos.

Bordes horizontales y verticales

Los bordes son una de las características más usadas para la detección de vehículos. El contorno de las traseras de los vehículos produce grandes diferencias de intensidad entre su contorno y el fondo de imagen, generando fuertes bordes verticales y horizontales. Las traseras de los vehículos contienen además muchas estructuras horizontales como el parachoques, la placa de matrícula, la luna trasera, etc, las cuales generan una elevada densidad de bordes horizontales en la imagen. Los métodos más simples consisten en extraer los bordes horizontales y verticales de la imagen por medio de operadores tales como Sobel, Canny ó Prewitt. De este modo, los grupos de bordes verticales y horizontales son candidatos a definir el contorno de un potencial vehículo [13,14].

En [15] se emplea la sombra que se genera debajo de los vehículos como región sobre la cual se localiza una hipótesis de vehículo. Posteriormente, en la región superior a la sombra, se comprueba la condición de bordes verticales y horizontales. En [16] se propone una búsqueda inicial de grupos de bordes en la imagen y posteriormente se realiza una segunda búsqueda más refinada de los bordes que compongan una forma rectangular. En [17] se lleva a cabo una extracción de bordes basada en la predicción del gradiente de vecindad, lo que produce unos buenos resultados ya que es menos sensible a los cambios de iluminación. En [18] se obtiene el mapa de perspectiva

inversa IPM que consiste en una vista en planta de la escena y donde se extraen los bordes verticales y horizontales.

El mayor inconveniente del uso de los bordes horizontales y verticales se debe a las interferencias que se pueden producir con los bordes correspondientes a otros elementos del fondo de la imagen (edificios, farolas, líneas de carril, etc). La característica de bordes es frecuentemente combinada con otras, con el fin de lograr una detección de vehículos más fiable [19].

Esquinas

La particular forma rectangular del contorno de las traseras de los vehículos es otra característica que puede ser explotada para hipotetizar modelos o plantillas compuestas por las cuatro esquinas de la misma. En [5], se utilizan cuatro plantillas diferentes para detectar en la imagen las cuatro esquinas de la trasera de un vehículo. Una región de la imagen se considera que es un potencial vehículo, si se encuentran coincidencias de las cuatro esquinas de la plantillas con un número suficiente de píxeles del mapa de bordes de la imagen. En [20], el proceso de detección de las esquinas se agiliza mediante máscaras de doble círculo concéntrico y las esquinas detectadas se agrupan en base a su orientación. Finalmente, las características de las esquinas de cada grupo son extraídas y usadas como entrada de un clasificador SVM (*Support Vector Machine*).

Las esquinas, son una característica que también se suele emplear en combinación con otras características de los vehículos con el fin de lograr métodos más robustos [5].

Textura

La textura de los vehículos es generalmente diferente a la de su entorno más próximo (asfalto). El asfalto de la carretera tiene por lo general una textura bastante homogénea, mientras que la de los vehículos presenta regiones con una elevada variación de intensidad. Además, las superficies de los vehículos son generalmente más brillantes que otros elementos del fondo de la escena. Las regiones de la imagen que contienen vehículos pueden ser segmentadas por medio del análisis estadístico de la textura de la imagen, por ejemplo de la entropía [21]. Sin embargo, esta técnica puede generar un elevado número de falsas detecciones, especialmente en entornos urbanos, debido a que la textura de algunos elementos de la escena puede ser similar a la de los vehículos.

Color

Los vehículos son elementos cromáticos, mientras que el asfalto es una superficie generalmente neutra (acromática). El color es por tanto, una buena característica que permite separar en la imagen las regiones que contienen a los vehículos de las regiones que contienen asfalto. Diferentes métodos han sido propuestos en la literatura en base a distintos espacios de color. Los espacios de color más empleados son el espacio RGB (*Red, Green, Blue*) y el HSI (*Hue, Saturation, Intensity*). En [22], se emplea un método de segmentación basado en intensidad y saturación en el espacio de color HSI, donde el matíz (Hue), es considerado irrelevante. En [23], se propone un espacio de color definido como la transformada de Karhunen-Loeve, el cual tiene una gran capacidad separando la carretera del vehículo. Para la clasificación de los píxeles se emplea un clasificador Bayesiano, asumiendo modelos Gaussianos para la clase “vehículo” y para la clase “carretera”.

El uso de la característica de color para la detección de vehículos está considerablemente condicionada por la gran variedad de colores que pueden tener los vehículos y por la fuerte influencia de la iluminación.

Luces traseras

Las luces traseras de los vehículos son la característica más usada para la detección de vehículos de noche. Bajo estas condiciones de iluminación, las luces traseras son una importante fuente de información. En [24], se propone un filtrado morfológico para detectar las parejas que conforman las luces traseras en una estrecha región de búsqueda. Además, el filtrado considera la forma, el tamaño y la mínima distancia entre vehículos para proporcionar las hipótesis a vehículo. En [25], se generan hipótesis mediante el filtrado de grupos de píxeles y posterior búsqueda de parejas de grupos en la imagen. Por otro lado en [26], un proceso de segmentación basado en un umbralizado multinivel es aplicado para la búsqueda de objetos brillantes en la imagen, los cuales son considerados como las luces traseras de un vehículo. En [27], se explota un filtro Top-Hat multinivel basado en la combinación de cuatro operaciones “opening” con elementos circulares. En [28], las luces traseras son empleadas en combinación con las características de simetría y bordes para obtener una mayor fiabilidad. En primer lugar, el método crea potenciales vehículos obteniendo picos en la distribución del color rojo de la imagen. Posteriormente se calcula la simetría del color rojo, obteniendo así el eje de simetría vertical de la trasera del vehículo. Finalmente las parejas de bordes que satisfagan simetría respecto al eje vertical son consideradas regiones de la imagen que potencialmente contienen un vehículo.

2.2.2.2 Métodos basados en estereovisión

Los sistemas basados en estereovisión, generalmente abordan la generación de hipótesis mediante la computación del mapa de disparidad. Alternativamente, otros métodos incorporan además la consideración de carretera plana, la cual facilita la tarea de detección de los vehículos. Ambos enfoques explotan las características de apariencia anteriormente descritas.

Mapas de disparidad (i.e., *Disparity Maps*)

El conjunto de diferencias entre píxeles correspondientes de la imagen izquierda y de la derecha es conocido como mapa de disparidad. Conocida la distancia y orientación de las dos cámaras, se puede crear un mapa tridimensional de la escena a partir del mapa de disparidad. La generación de hipótesis es generalmente llevada a cabo mediante la búsqueda de grupos de columnas de la imagen con una disparidad similar [28].

Los mapas de disparidad han sido usados frecuentemente para la detección de vehículos. En [29] la disparidad junto con el flujo óptico es usada como característica visual para la detección de objetos, donde cada pixel de la imagen es clasificado como objeto en movimiento o como fondo de la imagen. Sin embargo, el cálculo de disparidad no es fiable para todos los píxeles de la imagen. Así, varios métodos han sido propuestos para superar este problema. En [28-29], se propone la fusión de la estereovisión con la información de otros sensores. En [30], se calcula la homografía del plano de la carretera a partir de la imagen izquierda y derecha, donde únicamente son consideradas las correspondencias que reducen errores de re-proyección en ambas imágenes. En lugar de resolver el problema de las correspondencias localmente, en [28] se propone un método de optimización global basado en programación

dinámica, proporcionando una interpretación global consistente del par de imágenes.

El mayor inconveniente del uso de los mapas de disparidad en la fase de generación de hipótesis es que supone un considerable coste computacional.

Mapa de Perspectiva Inversa

El mapa de perspectiva inversa es una proyección virtual de todos los puntos de la imagen sobre el plano de superficie. Se asemeja a una transformación de la perspectiva cónica de la imagen adquirida, a la vista en planta de dicha escena. Asumiendo la condición de tierra plana, los puntos de la imagen en perspectiva cónica situados sobre el plano de superficie se proyectan correctamente en la vista en planta, mientras que los puntos elevados se proyectan incorrectamente. A pesar de esto, esta vista virtual en planta es muy útil, ya que permite apreciar el paralelismo entre los límites de la carretera y entre las líneas de carril. La transformación matemática que logra esta transformación de la perspectiva de la imagen es conocida como Mapeado de la Perspectiva Inversa IPM [32]. El IPM proporciona la vista en planta de la carretera enfrente del ego-vehículo. En [33], el IPM es usado para convertir la imagen izquierda en una imagen sin perspectiva y a su vez es transformada en una hipotética imagen de la vista derecha. Comparando la hipotética vista derecha con la vista derecha real, los objetos situados sobre el plano de la superficie pueden ser localizados. Alternativamente, en [34] las dos imágenes (derecha e izquierda) son proyectadas en el plano de la carretera mediante la transformación IPM. Los vehículos son hipotetizados si la diferencia de los mapas de las dos imágenes contienen grandes grupos de “non-zero” píxeles con una forma específica. Los “non-zero” píxeles corresponden con puntos elevados de la imagen, es decir,

con objetos sobre la superficie. En [35], los puntos elevados en la imagen y por tanto pertenecientes a objetos de la escena, son agrupados en base a su elevación, generando así hipótesis. Cada hipótesis es verificada mediante filtros Kalman. Éste método asume como conocida la vibración generada por el ego-vehículo y almacena la información acerca de la carretera. Mediante éste método es posible detectar vehículos a 150m de distancia bajo condiciones atmosféricas buenas.

En general, el funcionamiento de los sistemas de estereovisión está sujeto a una buena estimación de los parámetros de calibración de la cámara, lo cual es complicado con cámaras instaladas en vehículos en movimiento. Además, el coste de las estereocámaras disponibles en el mercado es mucho más elevado que el de las cámaras monoculares convencionales

2.2.2.3 Métodos basados en el movimiento

Los métodos basados en el movimiento explotan información temporal para detectar los vehículos. Los campos de flujo óptico de un vehículo en movimiento, pueden ser calculados mediante el emparejamiento de píxeles correspondientes a puntos característicos de dos imágenes sucesivas de la secuencia. El cálculo del flujo óptico crea un mapa con los vectores de movimiento de todos los píxeles (flujo óptico denso), o de un conjunto de elementos (flujo óptico esparcido). Los vehículos que se mueven más rápido que el observador producen un flujo óptico convergente con el punto de fuga de la imagen, mientras que el flujo óptico de los vehículos que se mueven más despacio diverge. El flujo óptico denso propuesto en [36], empareja cada píxel de las imágenes en función de su intensidad. Ésta técnica requiere un elevado coste computacional y por lo tanto no es adecuada para aplicaciones en tiempo real.

Por otro lado, el flujo óptico esparcido considera un conjunto de características de un vehículo, como las esquinas [37] o el color [38]. Una vez que los campos de flujo óptico son calculados, los objetos en movimiento son segmentados mediante el agrupamiento de campos de flujo considerando su posición, magnitud y ángulo. En [39], se consideran únicamente los bordes relevantes de la imagen y su flujo óptico es estimado mediante el método del gradiente (VIGM, *Virtual Intensity Gradient Method*), el cual asume un gradiente de intensidad lineal alrededor de los bordes. En [40], el flujo es calculado en puntos esparcidos de la imagen. Una cierta cantidad de puntos es determinada mediante el método de Monte Carlo, mientras que el resto es obtenido mediante una variable aleatoria. Las esquinas características de la imagen son extraídas en imágenes sucesivas en [37], obteniendo así los campos de flujo óptico. Posteriormente, los campos de flujo se agrupan en función de su variación. Finalmente, se obtiene el marco y el centroide de las agrupaciones resultantes, las cuales son consideradas potenciales vehículos. Este método requiere un elevado coste computacional. En [41], se propone una técnica para mejorar el cálculo del flujo mediante redes neuronales. En sus experimentos muestran que la precisión de la detección depende de la velocidad relativa entre el vehículo detectado y el ego-vehículo. La tasa de detección es baja con velocidades relativas pequeñas. Por esta razón, fusionan el flujo óptico con características de apariencia de los vehículos (la sombra bajo el vehículo y bordes), mejorando así la fiabilidad en la detección. Una técnica para la transformación de las agrupaciones de flujo óptico en objetos individuales en movimiento es propuesta en [42]. En primer lugar, las agrupaciones detectadas son proyectadas en un plano paralelo al plano de la carretera. Partiendo de un punto perteneciente al contorno de la trasera del vehículo, una región de búsqueda es establecida en base a la máxima y mínima anchura prevista del vehículo. Si la búsqueda es satisfactoria, una

coordenada es calculada a partir de las coordenadas de todas las agrupaciones de flujo compatibles en la región. Ésta coordenada es finalmente empleada para el cálculo de la anchura y del centro geométrico de la trasera del vehículo.

Los métodos basados en el movimiento son efectivos para la detección de vehículos. Sin embargo, requieren demasiado tiempo de procesado y se necesita analizar varias imágenes para detectar un vehículo. Además, al igual que la estereovisión, son muy sensibles a las vibraciones inducidas por el ego-vehículo en su movimiento.

2.2.3 Sombra bajo el vehículo. Fundamentos.

Un rasgo distintivo de los vehículos es la sombra que proyectan bajo sí mismos. Esta sombra se debe a que el vehículo ocluye la luz ambiental, la cual puede estar compuesta únicamente por la luz del cielo (días nublados) o puede estar formada por la luz del cielo y la luz del sol (condiciones soleadas). Debido a la forma de los vehículos, el espacio comprendido entre la parte baja del mismo y la superficie de la carretera es muy pequeño (menor que la altura de una rueda). De este modo, tanto en condiciones nubladas como en condiciones soleadas, la región de la carretera debajo del vehículo no está iluminada por la luz del sol y únicamente queda iluminada por una pequeña cantidad de luz lateral del cielo. Esto genera que la región de la carretera bajo el vehículo sea muy oscura, con poca textura y sin brillos. Incluso si el vehículo circula por una zona sombreada, la región de la carretera debajo del mismo es más oscura que sus alrededores. Por lo tanto, mientras haya luz ambiental, la sombra debajo del vehículo está siempre presente en la carretera, haciéndola una característica muy fiable para la detección de

vehículos de día. En la Figura 2.1 se pueden observar cuatro escenas de carretera en diferentes condiciones meteorológicas y por tanto, en diferentes condiciones de iluminación.

La Figura 2.1(a) muestra una imagen en un día nublado, donde la única iluminación de la escena consiste en luz difusa proveniente del hemisferio del cielo. Como se puede observar, la sombra bajo el vehículo precedente es considerablemente más oscura que la carretera. Esto se debe a que mientras la carretera está plenamente iluminada por la luz del cielo, la fracción de luz del cielo que incide en la región de la carretera bajo el vehículo es mucho menor (hay que tener presente, que la región de la carretera bajo el vehículo y la carretera plenamente iluminada, son efectivamente la misma superficie).

La Figura 2.1(b) muestra la imagen de un día soleado, donde la iluminación de la escena esta compuesta por la luz directa del sol y por la luz difusa del cielo. En este caso, la carretera está plenamente iluminada por ambas fuentes de luz, mientras que la región bajo el vehículo está solamente iluminada por una pequeña fracción de luz del cielo. En días soleados, la diferencia de intensidad entre la región de la carretera debajo del vehículo y la carretera plenamente iluminada es mucho mayor que en condiciones nubladas. Esto se debe a que tanto en condiciones nubladas como soleadas, la cantidad de luz que incide en la región de la carretera debajo el vehículo es la misma. Sin embargo, la cantidad de luz que incide sobre la carretera plenamente iluminada es mayor en días soleados. Por otro lado, también se puede apreciar el hecho de que la sombra bajo el vehículo es más oscura que las sombras laterales proyectadas por los objetos (vehículo precedente y farolas). Las regiones sobre las que se proyectan las sombras laterales no están iluminadas por la luz del sol, sin embargo, la cantidad de luz del cielo que incide sobre las mismas es mayor que la que incide bajo el vehículo, por




Figura 2.1: Ejemplos de la sombra bajo el vehículo. (a) día nublado, (b) día soleado, (c) día soleado pero con el vehículo circulando por una región sombreada de la carretera y (d) día lluvioso.

lo que la intensidad de las sombras laterales en la carretera es mayor que la intensidad de la región de la carretera debajo el vehículo.

En la Figura 2.1(c) se puede apreciar una escena en condiciones soleadas en la que el vehículo precedente circula por una zona sombreada de la carretera. En este caso, la sombra bajo el vehículo es todavía más oscura. La cantidad de luz de cielo que ilumina la región por la cual circula el vehículo es menor que la generada por todo el hemisferio, por lo que la fracción incidente bajo el vehículo es aún menor. En la Figura 2.1(c) también se observa que la sombra bajo el vehículo es la más oscura de toda la carretera. Finalmente, la Figura 2.1(d) muestra la imagen de una escena en días

lluviosos cuya iluminación es similar a la de un día nublado. Como se aprecia, la sombra bajo el vehículo es la región más oscura de la carretera.

La sombra bajo los vehículos se empleó por primera vez como característica para la detección de los mismos en [43], donde se establecen rangos de intensidad tanto para la región de la carretera no sombreada como para la región de la carretera bajo el vehículo. Los rangos se establecen para condiciones soleadas y condiciones nubladas. La detección de la sombra se reduce a la búsqueda en la imagen de zonas de la carretera cuya intensidad coincida con el rango previamente establecido. Sin embargo, las intensidades tanto de las sombras bajo los vehículos como de la carretera no sombreada varían en función del tipo de asfalto, por lo que este método puede ser válido para una carretera específica pero no puede ser usado como método general. Un segundo enfoque emplea un detector de bordes horizontales y aplica umbralización de intensidad y correlación de restricciones [44]. Sin embargo, ni las restricciones ni el método de umbralización empleados son especificados en [44].

Las intensidades de la sombra bajo el vehículo y de la carretera iluminada plenamente por la luz ambiental dependen tanto del tipo de asfalto como de la iluminación, por lo que el umbral de intensidad que las separa no es un valor fijo. Es por lo tanto necesario el empleo de una estrategia de umbralización que separe la sombra bajo los vehículos de la carretera plenamente iluminada. Con el fin de establecer un umbral de intensidad, varios métodos se basan en el hecho de que la sombra bajo los vehículos es siempre más oscura que la carretera plenamente iluminada por la luz ambiental [43]. La idea es determinar un nivel de gris aproximado del espacio libre disponible de la carretera enfrente del ego-vehículo. Así, las regiones de la imagen cuya intensidad sea menor que el nivel de gris de la

carretera tienen una alta probabilidad de ser la sombra bajo un vehículo.

En [45], varias máscaras generadas mediante la combinación de la intensidad y de la información del color son empleadas para segmentar la imagen en dos clases: carretera y no-carretera. Las regiones oscuras de la carretera con específicas restricciones (mínimo tamaño, altura y anchura) y que se localizan sobre la clase “carretera”, son consideradas candidatas a ser la sombra bajo un vehículo. Sin embargo, en [45] no se proporcionan los umbrales empleados para establecer las clases “carretera” y “no-carretera”. En [46], la carretera disponible enfrente del ego-vehículo es determinada por el método de la entropía y la detección de la sombra se realiza mediante umbralización de intensidad, filtrado morfológico y agrupamiento de regiones estabilizado a través del tiempo. Sin embargo, el umbral de intensidad que separa la sombra bajo el vehículo y la carretera plenamente iluminada, no es proporcionado en [46].

Una solución alternativa es propuesta en [47], donde el espacio libre disponible de carretera enfrente del ego-vehículo es considerado como la región central de la imagen delimitada por los bordes (obtenidos por el operador Sobel). Para la intensidad de gris de la carretera se asume una distribución normal y la sombra bajo un vehículo queda definida como aquella región de la imagen con una intensidad menor que el umbral $m-3\sigma$, donde m y σ son respectivamente el valor medio y la desviación típica del nivel de gris del conjunto de píxeles que conforman la carretera. Este método de umbralización demuestra su efectividad en ciertos escenarios (autopistas y carreteras generales) y bajo determinadas condiciones atmosféricas (días nublados). Sin embargo, en escenarios de carretera propios del tráfico urbano así como en condiciones soleadas, este método presenta ciertos problemas.

En primer lugar, la distribución normal de intensidad asumida para la

carretera no es siempre correcta porque la iluminación puede causar una variación no lineal del nivel de gris de la carretera. Así, incluso una carretera bien asfaltada puede presentar zonas donde la intensidad de sus píxeles es considerablemente distinta (ver Fig. 2.1(d)). Además, el umbral $m-3\sigma$ no es un límite superior para la intensidad de la sombra bajo un vehículo, sino que es un límite inferior de la intensidad de la carretera. Este hecho contribuye a falsas detecciones, ya que todos los elementos de la escena más oscuros que la carretera (incluidas las sombras laterales) son clasificados como sombra bajo un vehículo.

Por otro lado, la distancia entre vehículos circulando en tráfico urbano es menor que en autopistas y carreteras generales. El límite formado en la carretera por la sombra bajo un vehículo circulando próximo al ego-vehículo, puede aparecer en la imagen como una transición de intensidad gradual (difusa), cuya detección puede fallar fácilmente (ver Fig. 2.2). Este hecho puede conducir a incluir la sombra bajo el vehículo precedente como espacio libre de conducción. En la Figura 2.2, se aprecian tres imágenes de una secuencia en un día nublado con un mismo vehículo precedente circulando a tres distancias distintas del ego-vehículo. En la Figura 2.2(a), el vehículo precedente está bastante alejado del ego-vehículo y se puede apreciar como la sombra bajo el mismo causa una transición de intensidad fuerte en la carretera. El borde que genera la sombra en la carretera es correctamente detectado (los mapas de bordes de Fig. 2.2 *fila inferior* son calculados mediante el operador Sobel a partir de la imagen adquirida en escala de grises sin haber sido aplicado ningún proceso de suavizado). Sin embargo, en la misma imagen también se puede observar como las sombras bajo los vehículos tanto circulando en el carril paralelo como aparcados a la derecha de la vía, causan transiciones de intensidad graduales, las cuales no son detectadas por el operador de bordes. En Fig. 2.2(b) y 2.2(c), el vehículo




Figura 2.2: Detección de los bordes generados por las sombras bajo los vehículos en función de la distancia. (Arriba) imagen adquirida, (centro) imagen en escala de grises

precedente circula a una distancia más cercana y el borde que genera la sombra bajo sí mismo no es detectado por el operador. En estos casos, aplicando el método propuesto en [47], la sombra bajo los vehículos es incluida como espacio libre de la carretera, lo que puede generar errores a la hora de establecer el umbral de intensidad.

En la presente Tesis se presenta un método para detectar la sombra bajo los vehículos que es una alternativa a los métodos existentes en el estado del arte. Un hecho significativo es que el método propuesto mejora la efectividad y precisión en la detección de la sombra bajo los vehículos, proporcionando una elevada tasa de detección de hipótesis verdaderas y una baja tasa de falsas detecciones. El método opera correctamente bajo las diferentes

condiciones de iluminación, para todo tipo de asfalto e independientemente de la distancia existente entre el vehículo precedente y el ego-vehículo.

2.2.4 Método propuesto: Generación de Hipótesis.

2.2.4.1 Introducción

El método que se presenta para detectar la sombra bajo un vehículo se centra inicialmente en distinguir entre las transiciones de intensidad de la imagen originadas por la sombra bajo los vehículos de aquellas producidas por otros elementos de la escena. Para ello se comparan las propiedades cromáticas de los píxeles de la imagen a ambos lados de las transiciones de intensidad. A partir del conjunto formado por los píxeles superiores de las transiciones de intensidad resultantes y en base al hecho de que la sombra bajo un vehículo es una región de la carretera muy oscura, se establece un umbral de intensidad. De este modo, las regiones con menor intensidad que el umbral son candidatas a ser la sombra bajo un vehículo.

Para cada candidato a sombra, se refina el umbral de intensidad con el fin de descartar transiciones de intensidad debidas a posibles sombras adjacencias causadas por los elementos de la imagen. Finalmente, se aplica un filtrado morfológico en base al conocimiento previo de la pose y del tamaño de las traseras de los vehículos y se establece una región de interés ROI que abarca el área de la carretera enfrente del ego-vehículo. Únicamente los vehículos precedentes circulando dentro de la ROI son susceptibles a una colisión del tipo Frontal-Trasera con el ego-vehículo, por lo que únicamente los candidatos a sombra localizados dentro de la ROI son considerados las hipótesis generadas definitivas.

Las Figuras 2.3 y 2.4 ilustran las diferentes etapas del método de generación de hipótesis bajo diferentes condiciones de iluminación en escenarios reales urbanos.

2.2.4.2 Región de búsqueda en la imagen

En las ciudades y entornos urbanos existen muchos tipos de vías. Desde calles estrechas con un único carril, hasta amplias avenidas donde la carretera está formada por varios carriles. Con el fin de simplificar la escena capturada de la carretera, el área de búsqueda en la imagen es verticalmente reducido en base al conocimiento previo de la escena y asumiendo la condición de tierra plana. La cámara está instalada junto al espejo retrovisor del ego-vehículo y el área de búsqueda considerada en la imagen es una región rectangular que cubre la zona de la carretera más cercana al ego-vehículo, excluyendo así las regiones de la imagen correspondientes a distancias que no influyen en la marcha del ego-vehículo (ver Figs 2.3(a) y 2.4(a)).

2.2.4.3 Gradientes verticales de intensidad

La detección de la sombra bajo un vehículo precedente está inicialmente basada en la observación de que las sombras oscurecen la carretera [43]. De este modo, se extraen las transiciones verticales de intensidad de la imagen, que van desde los valores de gris de la carretera plenamente iluminada por la luz ambiental, hasta los valores de gris más oscuros correspondientes a la sombra bajo los vehículos (escaneando la imagen de abajo a arriba). Debido a la posición en la imagen de los vehículos precedentes, los píxeles superiores de las transiciones (los más oscuros) corresponden a la sombra, mientras que los píxeles inferiores (los más claros) corresponden a la carretera plenamente




Figura 2.3. Ejemplos de típicas escenas de tráfico urbano en días nublados, (a) región de búsqueda, (b) gradientes de intensidad verticales $M(x,y)$, (c) máscara binaria $M(x,y)$ tras la aplicación de las condiciones de saturación e intensidad, (d) $M(x,y)$ tras la umbralización por intensidad, (e) $M(x,y)$ tras la extracción de gradientes adyacentes debidos a sombras laterales, (f) grupos horizontales de gradientes de $M(x,y)$, (g) $M(x,y)$ tras filtrado morfológico y establecimiento de la




Figura 2.4. Ejemplos de típicas escenas de tráfico urbano en días soleados. (a) región de búsqueda, (b) gradientes de intensidad verticales $M(x,y)$, (c) máscara binaria $M(x,y)$ tras la aplicación de las condiciones de saturación e intensidad, (d) $M(x,y)$ tras la umbralización por intensidad, (e) $M(x,y)$ tras la extracción de gradientes adyacentes debidos a sombras laterales, (f) grupos horizontales de gradientes de $M(x,y)$, (g) $M(x,y)$ tras filtrado morfológico y establecimiento de la ROI y (h) hipótesis finales incluídas aquellas fuera de la ROI.

iluminada. Previamente a la extracción de las transiciones de intensidad, la imagen RGB de la escena es convertida a escala de grises I y un filtro paso bajo con un Kernel 3x1 es aplicado para disminuir ruido de la misma.

Dependiendo tanto de la iluminación ambiental como de la distancia que separa el ego-vehículo y el vehículo precedente, las transiciones de intensidad generadas por la sombra bajo el vehículo en la carretera pueden ser abruptas o graduales. La luz directa del sol y los vehículos precedentes alejados causan fuertes transiciones de intensidad en la carretera. Por otro lado, la luz del cielo (difusa) y los vehículos cercanos tienden a causar transiciones más suaves. Con el fin de detectar las transiciones de intensidad tanto fuertes como graduales, el proceso es llevado a cabo aplicando un operador de gradiente de intensidad sin ningún umbral,

$$M(x, y) = \begin{cases} 1, & I(x, y) - I(x+1, y) < 0 \\ 0, & \text{otherwise,} \end{cases} \quad (1)$$

donde x representa las filas e y las columnas respecto a la esquina superior-izquierda de la región de búsqueda de la imagen. La máscara binaria resultante $M(x, y)$ incluye los gradientes causados tanto por las sombras bajo los vehículos, como por cualquier otro elemento de la escena (ruido en el asfalto, los bordillos de la carretera, sombras laterales, líneas de carríl, etc). (ver Figs. 2.3(b) y 2.4(b)).

Con el fin de identificar los gradientes causados por las sombras bajo los vehículos, se explotan las propiedades espectrales y de intensidad de los píxels superiores e inferiores de los gradientes. El uso de gradientes en lugar de bordes proporciona mejores resultados cuando se comparan propiedades de los píxels a través de los límites de las sombras. Al contrario que ocurre

con los bordes de la imagen, los gradientes abarcan la penumbra de las sombras, que es la región de transición entre la umbra de la sombra y la carretera iluminada plenamente por la luz ambiental. Por lo tanto, los píxeles superiores (los más oscuros) de los gradientes corresponden a la umbra de la sombra, mientras que los píxeles inferiores (los más claros) corresponden a la carretera iluminada plenamente por la luz ambiental, evitando así el análisis de píxeles en penumbra.

Los gradientes de intensidad candidatos a ser gradientes originados por la sombra bajo un vehículo son obtenidos mediante cuatro condiciones:

1º Condición

En primer lugar, se considera el hecho de que la intensidad de cada componente roja, verde y azul de la carretera decrece a través de una transición sombra-carretera [48,49]. El análisis se lleva a cabo para cada gradiente i de $M(x,y)$. Los píxeles superior e inferior del gradiente de intensidad M_i bajo análisis son respectivamente (x_U,y) y (x_L,y) . Por lo tanto, el gradiente M_i pasa a ser candidato a gradiente causado por la sombra, si la intensidad del píxel superior $\{R_i(x_U,y), G_i(x_U,y), B_i(x_U,y)\}$ es menor que la del píxel inferior $\{R_i(x_L,y), G_i(x_L,y), B_i(x_L,y)\}$ para las tres componentes RGB. En cualquier otro caso, el gradiente M_i es descartado,

$$M_i(\overline{x_U x_L}, y) = \begin{cases} 1, & \begin{aligned} &R_i(x_U, y) < R_i(x_L, y) \\ &\text{and } G_i(x_U, y) < G_i(x_L, y) \\ &\text{and } B_i(x_U, y) < B_i(x_L, y) \end{aligned} \\ 0, & \text{otherwise.} \end{cases} \quad (2)$$

Esta condición es efectiva para descartar gradientes de intensidad causados por cambios de material y ruido en el asfalto con una pequeña diferencia de intensidad entre sus píxeles superiores e inferiores.

2º Condición

En segundo lugar, se tiene en cuenta la falta de iluminación debajo del vehículo, lo que hace que la región de la carretera bajo el mismo sea muy oscura y muy poco cromática.

La intensidad es una combinación lineal de las componentes RGB, por lo que el pequeño nivel de intensidad de la región de la carretera bajo un vehículo implica un bajo nivel de las componentes RGB (ver Fig. 2.5). En el espacio de color IHLS (*Improved Hue Luminance Saturation*) [50], la saturación IHLS es

$$S(x,y)=\max(R(x,y),G(x,y),B(x,y))-\min(R(x,y),G(x,y),B(x,y)). \quad (3)$$

La saturación IHLS (entendida como la proximidad de las tres componentes RGB a un mismo valor) decrece cuando la carretera pasa de estar iluminada plenamente por la luz ambiental a estar iluminada por una pequeña fracción de luz del cielo (región de la carretera bajo un vehículo). A medida que la oscuridad debajo del vehículo aumenta, las tres componentes RGB de la superficie disminuyen alcanzando valores cercanos a la escala de grises independientemente del color del asfalto (ver Fig. 2.5). De este modo, la percepción de la región de la carretera bajo el vehículo es cercana a la del eje acromático ($R \approx G \approx B$). Generalmente, el asfalto de la carretera es una superficie neutra y por lo tanto, su saturación IHLS es baja. En este caso, la




Figura 2.5: Escenas bajo diferente iluminación y asfalto. Las gráficas representan la variación de las componentes RGB (roja, verde, azul) y la saturación IHLS (negro) desde un punto de la carretera iluminada por la luz ambiental Pr hasta un punto en la región bajo el vehículo Ps (región acromática).

considerable disminución de iluminación bajo el vehículo, hace que la diferencia de intensidad de las tres componentes RGB sea menor o igual que en la carretera iluminada plenamente por la luz ambiental (ver Fig. 2.5).

De este modo, el gradiente M_i pasa a ser candidato a gradiente causado por la sombra, si la saturación IHLS del píxel superior $S_i(x_U, y)$ es igual o menor que la saturación IHLS del píxel inferior $S_i(x_L, y)$. En cualquier otro caso, el gradiente M_i es descartado,

$$M_i(\overline{x_U x_L}, y) = \begin{cases} 1, & S_i(x_U, y) \leq S_i(x_L, y) \\ 0, & \text{otherwise.} \end{cases} \quad (4)$$

La saturación IHLS evita la normalización por intensidad típica de

espacios de color como el HLS, HSI, HSV, etc, donde la saturación implica división por intensidad, la cual es prácticamente nula en zonas muy poco iluminadas. A esto se debe que regiones muy oscuras (acromáticas) en la imagen, alcancen valores de saturación normalizada mayores que otras regiones más coloridas. Este problema es inherente a la normalización en la zona acromática [51].

3º Condición

En tercer lugar, una nueva condición es propuesta en base a la observación de que la sombra bajo un vehículo es una región acromática caracterizada por un bajo valor de saturación IHLS. El objetivo de la siguiente condición es descartar gradientes cuyos píxeles superiores presentan mucho color, lo cual no es satisfecho por los píxeles superiores de los gradientes causados por la sombra bajo un vehículo. Varios métodos han sido propuestos para clasificar los pixeles como cromáticos o acromáticos. Un primer método es propuesto en [52] y usado más tarde en [49], donde un píxel es considerado acromático si la suma de sus componentes RGB es menor que 30. En [53], un píxel es clasificado como acromático cuando sus componentes RGB caen dentro de la esfera de radio $4 \cdot \sigma_N$ centrada en el origen del espacio RGB, donde σ_N es la desviación típica del ruido del sensor con baja iluminación. En [54,55], un píxel es considerado acromático si su intensidad es menor del 10% o mayor del 90% de la máxima intensidad, o si su saturación normalizada está por debajo del 10% de la máxima saturación. Finalmente, en [56], los píxeles son clasificados como acromáticos si su saturación normalizada está por debajo del 20% de la máxima saturación.

En este trabajo, se propone una clasificación donde un píxel es categorizado como cromático si el valor de su saturación IHLS es mayor de 60

en una escala de 256. Este umbral es muy conservador, centrándose en gradientes de la imagen con píxeles superiores muy coloridos como vehículos u otros elementos de la escena. De este modo, el gradiente M_i pasa a ser candidato a gradiente causado por la sombra, si la saturación IHLS del píxel superior $S_i(x_U, y)$ es menor o igual a 60. En cualquier otro caso, el gradiente M_i es descartado,

$$M_i(\overline{x_U x_L}, y) = \begin{cases} 1, & S_i(x_U, y) \leq 60 \\ 0, & \text{otherwise.} \end{cases} \quad (5)$$

4) Condición

Se propone una cuarta condición basada en la diferencia de intensidad entre el píxel superior y el inferior de los gradientes. Dependiendo de la iluminación ambiental y del tipo de asfalto, las intensidades de la carretera y de la sombra bajo un vehículo varían. Sin embargo, su diferencia en intensidad es considerable, incluso cuando el vehículo circula por una región sombreada de la carretera.

La intensidad de la luz reflejada por una superficie es el producto de la intensidad de luz incidente por la reflectancia de la superficie [57]. De este modo, en condiciones soleadas la intensidad de la luz reflejada $I_{road, sunny}(\lambda, p)$ en un punto p de la carretera iluminado por la luz del sol $I_{sun}(\lambda, p)$ y por la luz del cielo $I_{sky}(\lambda, p)$, y para una cierta geometría de visualización, es según [58] de la forma,

$$I_{road, sunny}(\lambda, p) = (I_{sun}(\lambda, p) + I_{sky}(\lambda, p)) \cdot \rho_{road}(\lambda, p), \quad (6)$$

donde λ es la longitud de onda y $\rho_{road}(\lambda, p)$ es la reflectancia de la carretera.

En condiciones nubladas y en carreteras a la sombra, la iluminación ambiental está compuesta únicamente por la luz del cielo, por lo que la intensidad de la luz reflejada $I_{road,cloudy}(\lambda, p)$ en un punto p de la carretera es,

$$I_{road,cloudy}(\lambda, p) = I_{sky}(\lambda, p) \cdot \rho_{road}(\lambda, p). \quad (7)$$

Por otro lado, la región de la carretera bajo un vehículo está iluminada por una pequeña cantidad de luz del cielo. La intensidad de luz reflejada $I_{s,vehicle}(\lambda, p)$ en un punto p de la carretera bajo el vehículo en condiciones soleadas, nubladas y en una carretera sombreada es

$$I_{s,vehicle}(\lambda, p) = \delta \cdot I_{sky}(\lambda, p) \cdot \rho_{road}(\lambda, p), \quad (8)$$

donde δ es una fracción de 1 que indica la cantidad de luz del cielo reflejada por la región de la carretera bajo el vehículo, la cual depende de la altura entre la parte baja del vehículo y la superficie de la carretera. Como la reflectancia de la carretera es constante, la diferencia de intensidad ΔI entre un punto de la carretera iluminada por la luz ambiental y un punto de la sombra bajo el vehículo en condiciones nubladas y en carreteras sombreadas es,

$$\begin{aligned} \Delta I &= I_{road,cloudy}(\lambda, p) - I_{s,vehicle}(\lambda, p) = (1 - \delta) \cdot I_{sky}(\lambda, p) \cdot \rho_{road}(\lambda, p) \\ &= (1 - \delta) \cdot I_{road,cloudy}(\lambda, p). \end{aligned} \quad (9)$$

El factor geométrico δ es pequeño por lo que $(1 - \delta)$ es elevado, causando una fuerte diferencia de intensidad entre la carretera plenamente iluminada por

la luz ambiental y la región de la carretera bajo el vehículo. En condiciones soleadas, la carretera está iluminada además por la luz del sol, lo que provoca que la diferencia de intensidad sea aún mayor.

Sin embargo, es difícil obtener un valor preciso de δ , ya que la altura entre la parte baja del vehículo y la superficie de la carretera depende de la marca y modelo. Como el objetivo es descartar gradientes cuya diferencia de intensidad no corresponda claramente con la fuerte diferencia de intensidad a través de una transición debida a la sombra de un vehículo, en base a resultados empíricos se propone un factor δ igual a 0.5, lo que hace la diferencia de intensidad ΔI_{SH} a través del gradiente producido por la sombra de un vehículo igual al 50% de la intensidad de la carretera iluminada plenamente por la luz ambiental, $\Delta I_{SH} = 0.5 \cdot I(x_L, y)$.

Por lo tanto, el gradiente M_i pasa a ser candidato a gradiente causado por la sombra, si la diferencia de intensidad entre el píxel superior $I(x_U, y)$ de la transición y el píxel inferior $I(x_L, y)$ es mayor o igual que ΔI_{SH} . En cualquier otro caso, el gradiente M_i es descartado,

$$M_i(\overline{x_U x_L}, y) = \begin{cases} 1, & I_i(x_L, y) - I_i(x_U, y) \geq 0.5 \cdot I_i(x_L, y) \\ 0, & \text{otherwise.} \end{cases} \quad (10)$$

Mediante un amplio rango de imágenes capturadas en carreteras tanto sombreadas como no sombreadas, se verificó que el umbral ΔI_{SH} es muy conservador (el porcentaje de luz del cielo incidente bajo el vehículo es menor que el 50% de la luz ambiental), lo que contribuye al descarte de gradientes producidos por sombras laterales suaves, ruido en el asfalto, etc.

Las Figuras 2.3(c) y 2.4(c) muestran la resultante máscara binaria $M(x, y)$ tras la aplicación de las condiciones de saturación y diferencia de intensidad

(Ecuaciones (2), (4), (5) y (10)). Se puede apreciar que los gradientes causados por sombras bajo los vehículos satisfacen las condiciones, mientras que la mayoría de gradientes producidos por otros elementos de la escena son descartados de $M(x,y)$. Sin embargo, los gradientes debidos a elementos con poco color como las líneas de carril, sombras laterales, bordillos y ruido todavía permanecen. Con el fin de identificar los gradientes correspondientes a las sombras bajo los vehículos, una umbralización de intensidad es llevada a cabo.

2.2.4.4 Umbralización por intensidad

Al contrario que los métodos que determinan el umbral para la sombra bajo los vehículos como límite inferior de la intensidad de la carretera [46], la estrategia de umbralización que se propone determina un límite superior para la intensidad de la sombra bajo los vehículos a partir de los píxeles superiores de los gradientes remanentes en la máscara binaria $M(x,y)$.

Los píxeles superiores de los gradientes en $M(x,y)$ corresponden con los píxeles más oscuros de la sombra bajo los vehículos, de las sombras laterales, de los bordillos, del ruido del asfalto, de las indicaciones sobre el asfalto, etc. Sin embargo, la sombra es más oscura que la carretera iluminada plenamente por la luz ambiental y por lo tanto, es más oscura que los píxeles superiores de los gradientes debidos a las indicaciones sobre el asfalto, ruido del asfalto y sombras laterales. Además, la sombra bajo los vehículos es generalmente más oscura que cualquier mancha de aceite en el asfalto [43,46,47] y que los bordillos (la cara vertical de un bordillo está sombreada debido a la oclusión de una mitad del hemisferio del cielo). Por lo tanto, de

todos los píxeles superiores remanentes en $M(x,y)$, aquellos correspondientes a la sombra bajo los vehículos son generalmente los más oscuros. De este modo, el valor medio de intensidad m del conjunto compuesto por los píxeles superiores de todos los gradientes en $M(x,y)$ es un límite superior de intensidad para la sombra bajo los vehículos,

$$m = \frac{1}{n_p} \cdot \sum_{i=1}^{n_p} I_i(x_U, y), \quad (11)$$

donde n_p es el número total de píxeles superiores de los gradientes.

Sin embargo, en escenas de carretera sin gradientes cuyos píxeles superiores presenten elevados valores de intensidad (correspondientes a indicaciones en el asfalto, sombras laterales, etc.), el valor medio de intensidad del conjunto no es un valor fiable como límite superior de intensidad de la sombra bajo los vehículos. Si se considera una máscara binaria $M(x,y)$ de un escena de la carretera donde únicamente aparece el grupo de gradientes correspondientes a la sombra bajo un vehículo, el límite superior de intensidad viene dado por el mayor valor intensidad de los píxeles del grupo, por lo tanto el valor medio de intensidad m sería un valor incorrecto como umbral intensidad para la sombra bajo el vehículo.

Con el fin de determinar si $M(x,y)$ presenta gradientes debidos a elementos cuyos píxeles superiores presenten altos valores de intensidad, se evalúa la desviación típica σ del conjunto de píxeles superiores, la cual indica la dispersión de los valores del conjunto respecto al valor medio. Un alto valor de la desviación típica indica que en el conjunto de gradientes, las intensidades de los píxeles superiores difieren considerablemente las unas de las otras, mientras que un valor bajo de la desviación típica indica un conjunto de gradientes donde el valor de las intensidades de los píxeles

superiores es similar. En base a resultados empíricos, se considera el primer caso y por tanto se aplica el valor medio m como umbral para la sombra bajo los vehículos, si la desviación típica es mayor que el 30% del valor medio de intensidad, $\sigma > 0.3 \cdot m$. En cualquier otro caso, no se aplica umbral de intensidad.

El gradiente M_i pasa a ser candidato a gradiente debido a la sombra bajo un vehículo bien para valores de desviación típica bajos o bien para valores de desviación típica altos siempre y cuando la intensidad del píxel superior $I_i(x_U, y)$ sea menor que el valor medio de intensidad m del conjunto. En cualquier otro caso, M_i es descartado,

$$M_i(\overline{x_U x_L}, y) = \begin{cases} 1, & \sigma \leq 0.3 \cdot m \\ & \text{or } (\sigma > 0.3 \cdot m \text{ and } I_i(x_U, y) < m) \\ 0, & \text{otherwise,} \end{cases} \quad (12)$$

donde,

$$\sigma = \sqrt{\frac{1}{n_p} \cdot \sum_{i=1}^{n_p} (I_i(x_U, y) - m)^2}. \quad (13)$$

Las Figuras 2.3(d) y 2.4(d) muestran la efectividad del valor medio de intensidad como umbral de intensidad, descartando gradientes debidos a indicaciones en el asfalto, ruido en el asfalto y una gran parte de sombras laterales.

Tanto en condiones nubladas como en regiones de la carretera sombreadas, la umbralización por intensidad generalmente conduce a mascarar binarias $M(x, y)$ formadas únicamente por los gradientes debidos a las sombras bajo los vehículos (ver Figuras 2.3(d) y 2.4(d)). Sin embargo, en días soleados, algunos

gradientes correspondientes a sombras laterales adyacentes al gradiente debido a la sombra bajo un vehículo, suelen satisfacer el umbral de intensidad y por tanto permanecen en la máscara binaria $M(x,y)$ (ver Figura 2.4(d) *izquierda*). Con el fin de identificarlos, un umbral de intensidad es aplicado individualmente sobre cada grupo de gradientes remanentes en $M(x,y)$.

En un grupo de gradientes compuesto por gradientes debidos a la sombra bajo un vehículo y a gradientes debidos a una sombra lateral (ver Figura 2.6(b)), las intensidades de los píxeles superiores de los primeros tienen un valor similar, el cual además es considerablemente menor que la intensidad de los píxeles de los gradientes debidos a la sombra lateral (ver Figura 2.6(c)). La desviación típica del conjunto de píxeles superiores de los gradientes del grupo es alta, mientras que la desviación típica del conjunto de píxeles superiores de un grupo formado únicamente por los gradientes debidos a la sombra bajo un vehículo es baja, ya que estos tienen valores de intensidad muy similares. Por lo tanto, la desviación típica σ (Ecuación (13)) es calculada y para valores menores que el 30% de la intensidad media del grupo, se considera que este está formado únicamente por gradientes debidos a la sombra bajo un vehículo y por lo tanto, no se aplica ningún umbral de intensidad. En cambio, si el valor de la desviación típica es elevado, se aplica el valor medio de intensidad del grupo como umbral de intensidad usando la Ecuación (13), donde en este caso, n_p es el número de píxeles superiores del grupo bajo análisis. Los gradientes del grupo cuyos píxeles superiores tengan una intensidad superior al umbral establecido son descartados como gradientes debidos a la sombra de un vehículo.

Las Figuras 2.4(e) *izquierda* y 2.6(d) muestran la máscara binaria $M(x,y)$ resultante tras la umbralización y tras descartar los gradientes debidos a la




Figura 2.6: Umbralizado por intensidad del conjunto de gradientes bajo el vehículo de la Fig. 2.4 izquierda. (a) Imagen inicial, (b) conjunto de gradientes debidos a la sombra bajo el vehículo y a la sombra lateral, (c) Intensidad de los píxels superiores del conjunto y (d) conjunto de gradientes resultante tras aplicar el segundo umbral.

sombra lateral causada por el vehículo. Los grupos de gradientes compuestos por gradientes debidos a la sombra bajo un vehículo en las Figuras 2.3(d) y 2.4(d) *derecha*, no presentan gradientes adjacentes debidos a sombras laterales, presentando unos valores de desviación típica bajos y por tanto no se les aplica el umbral de intensidad (ver las Figuras 2.3(e) y 2.4(e) *derecha*).

2.2.4.5 Filtrado morfológico

Tras la umbralización por intensidad, para obtener las hipótesis a vehículo finales se realiza un filtrado morfológico en base al conocimiento acerca de la pose y anchura de los vehículos en la imagen. Desde una perspectiva trasera del vehículo precedente, el borde superior del grupo de gradientes

correspondientes a la sombra bajo el vehículo es horizontal y su anchura es igual a la anchura del mismo. Debido a la perspectiva, la anchura (en píxeles) del vehículo precedente varía respecto a su posición vertical (en píxeles) en la imagen (ver la figura 2.7). La anchura de los vehículos depende de la marca y modelo por lo que una anchura estandar es considerada igual a la anchura del ego-vehículo. Además, el sistema está diseñado para detectar vehículos a una distancia máxima de 20m respecto del ego-vehículo. A 20m de distancia, la anchura estandar en la imagen es de 30 píxeles y la parte baja del vehículo esta localizada a 15 píxeles x-coordenada. A 1m de distancia, la anchura estandar en la imagen es de 178 píxeles y la parte baja del vehículo esta localizada a 100 píxeles x-coordenada (donde x-cordenada representa la fila de la región de búsqueda de la imagen). Por lo tanto, la relación entre la anchura v_{width} del vehículo precedente y su posición vertical en la imagen x viene dada por

$$v_{width}=3.9+1.74 \cdot x. \quad (14)$$

Esta relación es específica para cada resolución de la imagen y también a la elevación y ángulo de inclinación de la cámara instalada en el ego-vehículo.

El filtrado morfológico es como se describe a continuación. En primer lugar, extraemos los gradientes $M(x,y)$ que tienen una orientación horizontal mediante una operación “openning” con un elemento estructural basado en el mínimo valor de la anchura estandar del vehículo. Esta operación morfológica se centra en eliminar aquellas partes verticales e inclinadas de los grupos de gradientes en $M(x,y)$ como aquellos correspondientes a los bordillos de las aceras a las caras laterales de vehículos aparcados o vehículos circulando en un carril paralelo (ver las figuras 2.3(f) y 2.4(f)).



Figura 2.7: Variación de la anchura del vehículo V_{width} con respecto a su posición vertical en la imagen x .

En segundo lugar se realiza el filtrado de anchura estandar. Aquellos grupos de gradientes $M(x,y)$ cuya anchura se encuentre entre el 120% y el 80% de la anchura estandar a posición vertical computada son considerados candidatos a ser los gradientes debidos a la sombra bajo un vehículo (ver Figuras 2.3(g) y 2.4(g)). Para calcular la posición vertical de un grupo de gradientes, consideramos la posición vertical de sus píxeles superiores los cuales corresponden a la parte inferior del vehículo.

En tercer lugar, los marcos (bounding box) que contienen las hipótesis de vehículo son generadas. Con el fin de encuadrar correctamente las traseras de los vehículos, la anchura del grupo de gradientes es ampliada un 5% tanto a la izquierda como a la derecha de cada grupo de gradientes y una relación de aspecto estandar para las traseras de los vehículos es asumida. Así, consideramos que la altura del marco es igual al 130% de la anchura como se muestra en las Figuras 2.3(h) y 2.4(h).

2.2.4.6 Región de interés, ROI

Finalmente, una región de interés ROI es establecida abarcando el área de riesgo de colisión Frontal-Trasera (ver Figuras 2.3(g) y 2.4(g)). La ROI es considerada de modo que abarque una región de la carretera de 20m (15 x-coordinate) de distancia con una anchura igual a la anchura del ego-vehículo. Únicamente los vehículos que circulen dentro del área de seguridad son susceptibles a una posible colisión Frontal-Trasera, por lo tanto sólo esos vehículos son el objetivo del sistema. De este modo, los grupos de gradientes candidatos situados dentro de la ROI, bien total o parcialmente, son considerados las hipótesis finales del sistema como se muestra en las Figuras 2.3(h), 2.4(h) y 2.8.

2.2.4.7 Resultados

Los experimentos fueron llevados a cabo con secuencias de imágenes adquiridas en tráfico urbano real bajo diversas condiciones atmosféricas. La cámara empleada es una Trust Widescreen HD WebCam, equipada con 8 bit de profundidad de píxel y balance de blancos y tiempo de exposición automáticos, la cual proporciona imágenes de 240x320 píxeles de resolución.

Un total de 13,200 imágenes de carretera fueron capturadas, las cuales consisten en una amplia variedad de escenas de tráfico urbano compuestas por calles estrechas y amplias avenidas. Las imágenes fueron capturadas y procesadas en Matlab® en un ordenador portátil convencional.

La Figura 2.9 muestra algunos ejemplos de los resultados obtenidos en la etapa de generación de hipótesis, donde con el fin de mostrar mejor el funcionamiento del método, las hipótesis generadas tanto dentro como fuera de la ROI del ego-vehículo son mostradas. El método demuestra una gran



Figura 2.8: Hipótesis generadas a partir de los ejemplos de las Figs. 2.3 y 2.4.

robustez, ya que detecta correctamente los grupos de gradientes debidos a las sombras bajo los vehículos en días soleados, nublados y en regiones de la carretera sombreadas lateralmente por los elementos de la escena. El uso de la sombra bajo el vehículo como característica para la detección de los mismos puede conducir a detectar hipótesis que están fuera de los objetivos del sistema anticolisión frontal, como vehículos circulando en carriles paralelos (en ambas direcciones), vehículos aparcados a ambos lados de la calzada o vehículos en parte ocluidos (generalmente por otros vehículos). Sin embargo, como el sistema se centra en vehículos circulando dentro de la región de interés ROI, el número de hipótesis generadas es considerablemente reducido. Por otro lado, se puede apreciar que la trasera de los vehículos es correctamente enmarcada para los vehículos tanto alineados con los desalineados respecto al ego-vehículo. La Figura 2.10 muestra algunos ejemplos de las hipótesis generadas.

Los resultados cuantitativos de la etapa de generación de hipótesis son mostrados en la Tabla 2.1, donde una hipótesis es considerada como positiva P si la trasera del vehículo es correctamente enmarcada (ver la Figura 2.10(a)). Las hipótesis que contienen vehículos cuyas traseras son incorrectamente enmarcadas $FNVI$ (ver la Figura 2.10(b)) son incluidos como falsos negativos junto con vehículos no detectados $FNVM$.



Figura 2.9. Ejemplos de los resultados de la generación de hipótesis incluídas aquellas fuera de la ROI.

Los resultados muestran una elevada tasa de detección de positivos PR , alcanzando el 98.04% y el 97.64% en condiciones nubladas y en condiciones soleadas respectivamente. La pérdida en la detección de positivos no se debe principalmente a vehículos no detectados sino a vehículos cuyas traseras son incorrectamente encuadradas. En ambas condiciones atmosféricas, el número de vehículos no detectados es muy pequeño lo que demuestra que el método de generación de hipótesis es muy fiable.




Figura 2.10. Ejemplos de las hipótesis generadas obtenidas. (a) hipótesis positivas, (b) hipótesis de vehículos incorrectamente enmarcados y (c) falsos positivos correspondientes a no vehículos o vehículos fuera de los objetivos del sistema.

En cuanto a los falsos positivos (ver la Figura 2.10(c)), el número de hipótesis conteniendo a un no-vehículo FP es relativamente bajo para una fase previa de la detección como es la fase de generación de hipótesis, alcanzando unas tasas de FPR del 6.79% y del 4.66% para condiciones nubladas y soleadas respectivamente. El hecho de condiseñar únicamente las hipótesis dentro del área de interés contribuye en gran medida a la baja tasa de falsos positivos.

El comportamiento del método de generación de hipótesis propuesto es comparado con el bien conocido método propuesto en [47], el cual es

Tabla 2.1 Resultados de la generación de hipótesis

	Nublado	Soleado
Número total de frames	7,920	5,280
Número total de vehículos dentro de la ROI (V)	7,303	4,589
Número total de hipótesis generadas (H)	7,830	4,806
Positivos: vehículos correctamente enmarcados (P)	7,160	4,481
Falsos positivos: hipótesis de no-vehículos (FP)	532	224
Hip. de veh. incorrectamente enmarcados ($FNVI$)	138	101
Falsos negativos: vehículos no detectados ($FNVM$)	5	7
Tasa de positivos (PR)	98.04%	97.64%
Tasa de falsos positivos (FPR)	6.79%	4.66%
Tasa de falsos negativos (FNR)	1.95%	2.35%

$$PR(\%) = \frac{P}{V} \cdot 100, \quad FPR(\%) = \frac{FP}{H} \cdot 100, \quad FNR(\%) = \frac{FNVI + FNVM}{V} \cdot 100$$

ampliamente usado en el el estado del arte, y donde la sombra bajo los vehículos es definida como la región superior de los bordes de la imagen con una intensidad menor que el umbral $m \cdot 3 \cdot \sigma$, donde m and σ son la media y la desviación típica del conjunto de píxeles que conforman el espacio libre de conducción definido por los bordes de la imagen. Tras un filtrado morfológico, los bordes debidos a gradientes correspondientes a las sombras laterales son detectados y eliminados. Desgraciadamente, las especificaciones del filtrado morfológico así como el método para la identificación y extracción de las sombras laterales no son proporcionadas en [47], por lo que una comparación cuantitativa entre ambos métodos no es posible. Por lo tanto, nos centramos únicamente en comparar el umbral de intensidad Th_1 propuesto en [47] y el umbral Th_2 propuesto mediante dos ejemplos ilustrativos.

La figura 2.11(a) muestra el área de búsqueda en la imagen adquirida de la escena de carretera con vehículos precedentes y la Figura 2.11(b) muestra




Figura 2.11. Escena en día nublado: (a) región de búsqueda, (b) su histograma de grises. *Columna izquierda* (método propuesto en [46]): (c) mapa de bordes, (e) espacio libre de conducción, (g) histograma del área libre de conducción y (i) mapa de bordes tras el umbralizado de intensidad. *Columna derecha* (método propuesto): (d) gradiente de intensidad vertical, (f) $M(x,y)$ tras la aplicación de las condiciones de saturación e intensidad, (h) histograma del conjunto de píxeles superiores de los gradientes y (j) $M(x,y)$ tras el umbralizado de intensidad.

el histograma de dicha región obtenido a partir de la imagen en escala de grises, donde se pueden apreciar dos picos principales de intensidad. El pico más grande corresponde con la intensidad de los píxeles de la carretera y el pico más pequeño (situado al la izquierda del primero) corresponde a la intensidad de los píxeles de la región de la carretera bajo los vehículos (la

sombra bajo los vehículos). Los píxeles correspondientes a las indicaciones en la carretera y a regiones claras de la imagen se localizan a la derecha del pico correspondiente a los píxeles de la carretera, mientras que los píxeles correspondientes a manchas de aceite en el asfalto, bordillos y sombras laterales se localizan entre ambos picos principales.

El método propuesto en [47] establece el umbral de intensidad que separa la carretera y la sombra bajo los vehículos Th_1 como el límite inferior de la intensidad del espacio libre de la carretera (ver Fig. 2.11(e)), proporcionando unos valores de $m_I=105.87$, $\sigma_I=15.27$ y $Th_I=60.04$ (ver Fig. 2.11(g)). Los bordes cuya región superior presenten una intensidad menor que el umbral Th_1 son clasificados como candidatos a ser la sombra bajo un vehículo (ver la Figura 2.11(i)).

Por otro lado, el umbral de intensidad que se propone en este trabajo, es establecido considerando los píxeles superiores de los gradientes remanentes en la máscara binaria $M(x,y)$ tras la aplicación de las condiciones de saturación y diferencia de intensidad (Ecuaciones (2), (4), (5) y (10)) (ver la Figura 2.11(f)). Como se comentó anteriormente, las intensidades de los píxeles superiores de los gradientes son menores que la intensidad de la carretera por lo que el umbral de intensidad que proponemos Th_2 es menor que el umbral Th_1 . Obtenemos unos valores $m_2=34.85$, $\sigma_2=28.81$, y como $\sigma_2 > 0.3 \cdot m_2$, el umbral de intensidad resulta $Th_2=34.85$ (ver la Figura 2.11(h)). De este modo, todos aquellos gradientes de la imagen cuyos píxeles superiores presenten una intensidad menor que el umbral Th_2 son clasificados como gradientes debidos a la sombra bajo un vehículo (ver Figura 2.11(j)).

Si comparamos ambos umbrales (ver la Figura 2.11(b)), el umbral Th_2 es más cercano al nivel de intensidad de las sombras bajo los vehículos que el

umbral Th_1 , y por lo tanto la umbralización realizada con Th_2 es más efectiva descartando un mayor número de gradientes que no son debidos a la sombra bajo un vehículo (ver Figuras 2.11(i) y 2.11(j)). Este hecho pasa a tener mucha más relevancia en escenas con la presencia de sombras laterales o manchas oscuras en el asfalto.

La Figura 2.12(a) muestra el área de búsqueda de la imagen de un escena en presencia de sombras laterales causadas por los vehículos aparcados y la Figura 2.12(b) muestra el histograma de la imagen en escala de grises. El nivel de intensidad de las sombras laterales es mayor que el de las sombras bajo los vehículos y menor que el de la carretera (ver la Figura 2.12(b)). De acuerdo con el método propuesto en [47], a partir de los píxeles que conforman espacio libre de conducción enfrente del ego-vehículo, obtenemos $m_I=170.87$, $\sigma_I=15.43$ and $Th_I=124.67$ (ver la Figura 2.12(g)). Como se puede observar en la Figura 2.12(b), el límite inferior de intensidad de los píxeles de la carretera Th_I es mucho mayor que el nivel de intensidad de las sombras laterales, por lo que los bordes de las mismas son clasificados como aquellos debidos a la sombra bajo un vehículo (ver la figura 2.12(i)).

Por otro lado, los píxeles superiores de los gradientes en $M(x,y)$ proporcionan unos valores: $m_2=45.61$, $\sigma_2=18.06$ and as $\sigma_2 > 0.3 \cdot m_2$, $Th_2=45.61$ (ver la Figura 2.12(b)). El umbral de intensidad que se propone en este trabajo Th_2 es considerablemente menor que el umbral Th_I (ver la Figura 2.12(b)), y menor que el nivel de intensidad de la mayor parte de las sombras laterales, desechado de este modo sus correspondientes gradientes de $M(x,y)$ (ver la figura 2.12(b)). El diferente funcionamiento de Th_I y Th_2 puede ser apreciado en las Figuras 2.12(i) y 2.12(j).

Mediante un amplio rango de imagenes de test, verificamos que el umbral de intensidad para separar los píxeles de la sombra bajo los vehículos del




Figura 2.12. Escena en día soleado: (a) región de búsqueda, (b) su histograma de grises. *Columna izquierda* (método propuesto en [46]): (c) mapa de bordes, (e) espacio libre de conducción, (g) histograma del área libre de conducción y (i) mapa de bordes tras el umbralizado de intensidad. *Columna derecha* (nuestro método): (d) gradiente de intensidad vertical, (f) $M(x,y)$ tras la aplicación de las condiciones de saturación e intensidad, (h) histograma del conjunto de píxeles superiores de los gradientes y (j) $M(x,y)$ tras el umbralizado de intensidad.

resto de píxeles de la imagen es mucho más preciso que el propuesto en [46], produciendo unos mejores resultados de umbralización especialmente en escenas bajo condiciones soleadas en presencia de sombras laterales, manchas en el asfalto y parches oscuros de asfalto.

2.3 Verificación de Hipótesis

2.3.1 Introducción

La verificación de hipótesis consiste en un análisis profundo de las regiones de la imagen contenidas en las hipótesis generadas. En esta etapa se validan las imágenes que contienen potenciales vehículos. Las principales técnicas de verificación de hipótesis se pueden clasificar en tres tipos: 1) métodos de correlación basados en plantillas, 2) métodos basados en aprendizaje de la apariencia y 3) métodos basados en la apariencia.

Los métodos basados en plantillas usan patrones predefinidos de la clase “vehículo” y realizan correlación entre la plantilla y la hipótesis a verificar. Los métodos basados en aprendizaje aprenden las características de la clase “vehículo” a partir de un conjunto de imágenes de entrenamiento. Finalmente, los métodos basados en apariencia emplean las características de las traseras de los vehículos descritas en la sección 2.2.2.1 de este mismo capítulo.

2.3.2 Estado del Arte

Métodos basados en plantillas

Los métodos basados en plantillas usan patrones predefinidos de la clase “vehículo” y aplican correlación entre la hipótesis y la plantilla. En [59] se propone un método para la verificación de hipótesis basado en la matrícula y la luna trasera de los vehículos. Sin embargo no se proporcionan resultados cuantitativos. En [46] se propone una plantilla basada en la observación de

que la trasera de los vehículos tiene una forma en “U” (un borde horizontal, dos bordes verticales y dos esquinas que conectan los el borde horizontal con los verticales). Las luces traseras son empleadas como plantilla en [24], centrándose en la verificación para sistemas de detección de vehículos destinados a funcionar de noche. En [60], se presenta una plantilla que contiene información acerca de la simetría de las traseras de los vehículos, de la forma rectangular de las mismas y de la específica relación entre anchura y altura que presentan los vehículos. Inicialmente se analiza la hipótesis en busca del contorno del vehículo mediante perspectiva y restricciones de tamaño y posteriormente se evalúa la simetría.

En general, los métodos basados en plantillas requieren poco tiempo de procesado, pero generan cierta incertidumbre ya que puede haber elementos en la imagen que satisfagan las características empleadas para conformar las plantillas.

Métodos basados en el aprendizaje de la apariencia

Los métodos de verificación de hipótesis que emplean la apariencia de los vehículos son tratados como un problema de clasificación de dos clases, “vehículo” y “no vehículo”. Construir un patrón de clasificación robusto, implica la búsqueda de un límite de decisión óptimo entre las dos clases, lo cual es complicado dada la amplia variabilidad de la clase “vehículo”. Un método posible consiste en el aprendizaje del límite de decisión en base a un clasificador entrenado mediante un conjunto de características de los vehículos. Los métodos basados en la apariencia aprenden las características de los vehículos en base a un conjunto de imágenes de entrenamiento, las cuales capturan la variabilidad de la clase “vehículo”. Generalmente la variabilidad de la clase “no vehículo” es también entrenada con el fin de

mejorar el funcionamiento del sistema. En primer lugar, un gran número de imágenes de entrenamiento es requerido y cada imagen es representada por un conjunto de características locales y globales. El límite de decisión entre las clases “vehículo” y “no vehículo” es aprendido por entrenamiento del clasificador o por el modelado de la distribución de probabilidad de las características de cada clase. Varios métodos de extracción de características han sido propuestos. En [61] se propone para la extracción de características el uso del análisis de las componentes principales (PCA) junto con un clasificador de tipo vecino-cercano. Sin embargo el conjunto de imágenes de entrenamiento es pequeño. En [62], se extrae información acerca de los bordes, y el histograma de una región de interés es proporcionado a la red neuronal para la clasificación. Un método estadístico es propuesto en [63], donde cada imagen de un vehículo es representada como una constelación de características locales. El método de expectación-maximización (EM) es empleado para aprender los parámetros de la distribución de probabilidad de las constelaciones. Este método emplea 200 imágenes de entrenamiento y proporciona un 87% de precisión. Finalmente, los filtros Gabor para la extracción de características son empleados en [64]. Los filtros Gabor proporcionan un mecanismo para obtener la orientación de los bordes. Las traseras de los vehículos contienen fuertes bordes con diferente orientación, por lo que este tipo de características son muy efectivas. La clasificación es llevada a cabo mediante Support Vectors Machine (SVM), proporcionando una precisión del 94.81%.

Los métodos basados en aprendizaje tienen como inconveniente que requieren por lo general un gran número de imágenes de entrenamiento.

2.3.3 Método propuesto

2.3.3.1 Introducción

La estrategia de verificación de hipótesis HV que se propone en este trabajo, está basada en la evaluación de características de la apariencia comunes a todas las traseras de los vehículos.

Los candidatos a vehículo proporcionados por la fase de generación de hipótesis (ver Figura 2.10), son verificados usando una combinación de tres características: bordes horizontales, verticales y simetría. Un candidato a vehículo ha de satisfacer las tres condiciones para ser finalmente verificado como vehículo.

2.3.3.2 Bordes horizontales y verticales

La trasera de los vehículos contiene muchas estructuras horizontales y verticales como el contorno del vehículo, la placa de matrícula, la luna trasera, el parachoques, etc, los cuales generan una elevada densidad de bordes en la imagen. En este trabajo, los bordes verticales y horizontales son extraídos separadamente de la imagen en escala de grises mediante el operador Sobel [65], como se muestra en la Figura 2.13. Como se puede observar, los bordes verticales de un candidato positivo corresponden principalmente con el contorno vertical del vehículo, mientras que la densidad de bordes en la región central es debida básicamente a bordes horizontales. En la Figura 2.13 también se puede apreciar como el fondo de la imagen influencia considerablemente la correcta detección de bordes del contorno del vehículo. Debido a la perspectiva, la parte superior de la imagen está repleta de elementos de la escena, lo que puede conducir a una pérdida




Figura 2.13. Hipótesis positiva: (a) hipótesis, (b) bordes verticales, (c) bordes horizontales, (d) puntos de simetría de intensidad y (e) eje de simetría Y_s .

de bordes verticales del vehículo. Sin embargo, la región inferior del fondo de la imagen corresponde con el asfalto el cual es generalmente homogéneo favoreciendo la correcta detección de los bordes verticales correspondientes al contorno del vehículo.

Se propone la computación de los bordes verticales únicamente dentro de un área de interés IA_1 la cual comprende el 40% de la altura de la hipótesis medida desde la parte inferior de la imagen (ver Fig. 2.13(b)). De este modo, definimos la densidad de bordes verticales del candidato a vehículo V_{edge} con unos valores comprendidos entre $[0, 1]$ como,

$$V_{edge} = \frac{1}{2 \cdot 0.4 \cdot R_x} \cdot \sum_{x,y \in IA_1} e_v(x,y), \quad (15)$$

donde $e_v(x,y)$ es la intensidad de bordes verticales de un píxel (x,y) cuyos

posibles valores pueden ser 0 o 1, y donde R_x es la altura de la imagen del candidato. Los candidatos que presenten una alta densidad de bordes verticales ($V_{edge} \geq T_V$) son clasificados como potenciales vehículos.

Por otro lado, se propone la computación de los bordes horizontales a lo largo y ancho de toda la imagen de la hipótesis (ver Fig. 2.13(b)). De este modo, definimos la densidad de bordes horizontales del candidato a vehículo H_{edge} con unos valores comprendidos entre $[0, 1]$ como el número de píxeles que conforman los bordes horizontales dividido por $3 \cdot R_y$,

$$H_{edge} = \frac{1}{3 \cdot R_y} \cdot \sum_{x,y \in R} e_H(x,y), \quad (16)$$

donde es la intensidad de bordes horizontales de un píxel (x,y) cuyos posibles valores se encuentran entre 0 y 1, y donde R_y es la anchura de la imagen del candidato. Los candidatos que presenten una alta densidad de bordes horizontales ($H_{edge} \geq T_H$) son clasificados como potenciales vehículos.

Ambos umbrales fueron empíricamente elegidos a partir de un conjunto de candidatos positivos obtenido bajo condiciones tanto soleadas como nubladas. Los valores óptimos obtenidos para sendos umbrales son $T_H = T_V = 0.8$.

2.3.3.3 Simetría

La vista trasera de un vehículo es generalmente simétrica respecto a un eje vertical central. Con el fin de abarcar toda clase de vehículos, la altura de la hipótesis conteniendo un vehículo es determinada en la Sección 2.2.4.5 como el 130% de la anchura. De este modo, se consigue el correcto encuadramiento de vehículos altos (furgonetas y camionetas). Sin embargo, la región superior

de la imagen conteniendo un coche turismo o berlina, es generalmente fondo de imagen, el cual puede no satisfacer la condición de simetría (ver la Fig. 2.13). La altura de los coches no es fija por lo que un valor estandar es asumido. El valor estandar es calculado empíricamente mediante un conjunto de hipótesis positivas conteniendo distintos modelos de vehículo, obteniendo un valor medio para la altura de los coches igual al 80% de la altura de la imagen que contiene al candidato.

En este trabajo se propone la computación de la simetría vertical de intensidad, de un área de interés de la imagen IA_2 que comprende el 80% de la altura total de la imagen conteniendo la hipótesis, medida desde la parte inferior (ver la Figura 2.13(d)). De este modo, se evita la región superior de la imagen la cual puede estar formada por el fondo de imagen.

Un eje vertical barre la imagen de izquierda a derecha calculando la simetría para cada fila de la imagen. El valor de simetría de un píxel (x,y) es calculado como la suma de píxeles simétricos a lo largo de la fila x y respecto al eje vertical situado en la columna y mediante,

$$Symmetry (x,y) = \begin{cases} \sum_{y'=y+1}^{y'=R_y} s(x,y') & \text{if } 2 \leq y \leq \frac{R_y}{2} \\ \sum_{y'=y+1}^{y'=R_y} s(x,y') & \text{if } \frac{R_y}{2} \leq y \leq R_y - 1, \end{cases} \quad (17)$$

donde,

$$s(x,y') = \begin{cases} 1, & I(x,y') - I(x, 2 \cdot y - y') \leq T \\ 0, & \text{otherwise.} \end{cases} \quad (18)$$

Dos píxeles (x,y) y $(x, 2 \cdot y - y')$ equidistantes y en direcciones opuestas respecto al píxel (x,y) , son simétricos respecto a este último si sus intensidades son

iguales. Sin embargo, la iluminación ambiental propia de los ambientes exteriores puede hacer que las intensidades de dos puntos pertenecientes a una misma superficie varíe. Por lo tanto, en base a ensayos empíricos consideramos una tolerancia de intensidad T_{igual} a 15 en una escala de 256 (ver la Ecuación 18)). Esta tolerancia de intensidad es bastante restrictiva, rechazando simetría de puntos sobre una misma superficie que varíen en una pequeña cantidad de intensidad.

Una vez que la simetría vertical es calculada para todos los píxeles de cada fila, se determina el píxel con máximo valor de simetría. La Figura 2.13(d) muestra los píxeles con máxima simetría de cada fila superpuestos en la imagen de la hipótesis a vehículo. La columna conteniendo el eje de simetría Y_s es definida como el valor medio de las coordenadas y de los puntos de máxima simetría de cada fila (ver Fig. 2.13(6)). Además, se considera un rango de tolerancia del 10% de la anchura de la imagen de la hipótesis R_y hacia ambos lados (izquierdo y derecho) del eje de simetría Y_s (ver la Fig. 2.13(d)). De este modo, si más del 70% de los puntos de máxima simetría de cada fila, caen dentro del rango de tolerancia establecido, la hipótesis es considerada simétrica respecto al eje Y_s , y por tanto el candidato es clasificado como un potencial vehículo. En cualquier otro caso, se considera que la hipótesis no es simétrica y por lo tanto, es descartada como potencial vehículo. Ambos rangos de tolerancia (20% de la anchura de la imagen conteniendo la hipótesis y el 70% del total de los puntos de máxima simetría de cada fila), son calculados experimentalmente a partir de un conjunto de hipótesis positivas en condiciones nubladas y soleadas.

2.3.3.4 Resultados

Para evaluar el comportamiento de la etapa de verificación de hipótesis propuesta, se emplean las 12,636 hipótesis H proporcionadas por la fase de generación de hipótesis tanto en condiciones nubladas como soleadas. Los resultados de la fase HV estan presentados en la Tabla 2.2. Como se puede apreciar, el número de hipótesis correctamente verificadas como vehículo V_v es muy elevado, alcanzando una tasa de positivos PVR del 99.5%. La mayoría de las hipótesis correspondientes a un vehículo correctamente enmarcado son verificadas como vehículo, mientras que ninguna de las hipótesis correspondientes a un vehículo incorrectamente enmarcado satisfacen las restricciones de la fase de HV . La verificación de estas últimas generalmente falla con la condición de bordes verticales. En cuanto a los falsos positivos, el número de no-vehículos verificados como vehículo FP_v es considerablemente bajo, alcanzando una tasa $FPVR$ igual al 1.205%.

Tabla 2.2 Resultados de la verificación de hipótesis

Número total de hipótesis generadas (H)	12,636
Hipótesis conteniendo un vehículo (P)	11,641
Hipótesis conteniendo un no-vehículo (FP)	995
Número de vehículos verificados (V_v)	11,583
Número de vehículos descartados (V_d)	58
Número de vehículos verificados como no-vehículo (FP_v)	12
Número de no-vehículos descartados como vehículo (FP_d)	983
Tasa de positivos(PVR)	99.5%
Tasa de falsos positivos ($FPVR$)	1.205%

$$PVR(\%) = \frac{V_v}{P} \cdot 100, \quad FPVR(\%) = \frac{FP_v}{FP} \cdot 100$$

Finalmente, la Tabla 2.3 muestra los resultados de ambas fases HG y HV analizadas como sistema conjunto. El sistema es capaz de detectar el 97.5% de los vehículos precedentes circulando en el área de seguridad ROI, haciendo que el sistema de detección de vehículos sea muy efectivo y muy fiable bajo las diferentes condiciones atmosféricas.

En cuanto al tiempo de procesamiento del sistema, se ha de decir que no es constante para cada ciclo y depende de dos factores. En primer lugar, depende de si hay o no presencia de vehículo en la escena y en caso afirmativo, depende de la distancia a la que el vehículo precedente se encuentre. Cuanto menor sea la distancia entre el ego-vehículo y el vehículo precedente, mayor es el tamaño de la imagen de la hipótesis generada conteniendo la trasera del vehículo, por lo que la imagen a verificar como vehículo es mayor. Esto supone un coste computacional más elevado que la verificación de hipótesis alejadas, cuya imagen que las contiene es de menor tamaño. El tiempo medio de procesamiento alcanzado es de 248.4768 ms, el cual supone el análisis de 4 imágenes por segundo (4 fps). El sistema fue desarrollado y probado mediante un ordenador portátil convencional con las limitaciones que esto supone. Sin embargo, se debe decir que el algoritmo desarrollado emplea métodos mucho más rápidos que procesos propios de la monovisión basados en flujo óptico o mapeado de la imagen inversa, los

Tabla 2.3 Resultados del sistema de detección de vehículos

Número de vehículos dentro de la ROI (V)	11,892
Número de vehículos detectados (VD)	11,583
Número de vehículos no detectados (VND)	309
Tasa de detección de vehículos (VDR)	97.4%
Tasa de falsos negativos (FNR)	2.59%

$$VDR(\%) = \frac{VD}{V} \cdot 100, \quad FNR(\%) = \frac{VND}{V} \cdot 100$$

cuales generalmente satisfacen la condición de tiempo de procesado. Por lo tanto, se espera que el algoritmo desarrollado alcance un mayor número de imágenes analizadas por segundo mediante una unidad de procesado preparada al efecto.

2.4 Conclusiones

Se ha presentado un nuevo sistema para la detección de vehículos precedentes en la trayectoria en tráfico urbano basado en visión por computador para entrar a formar parte de un sistema anticolisión frontal FCAS para evitar colisiones Frontal-Trasera. El método propuesto consiste en dos etapas: generación de hipótesis y verificación de hipótesis. La contribución principal se presenta en la generación de hipótesis donde proponemos una estrategia efectiva para la detección de las sombras bajo los vehículos, la cual supera dificultades importantes como la presencia de sombras laterales en la carretera y fondos de imagen repletos de elementos.

Las hipótesis son generadas mediante la comparación de los píxeles superiores e inferiores de los gradientes de intensidad generados en la carretera y mediante filtrado morfológico. Para candidato, una refinada umbralización es llevada a cabo para eliminar las transiciones correspondientes a sombras laterales. Finalmente, las hipótesis son verificadas en base a características de los vehículos extraídas de la trasera de los mismos.

Los ensayos llevados a cabo en tráfico urbano real bajo diferentes condiciones ambientales, demuestran una gran robustez y efectividad del método propuesto en la detección del vehículo precedente en la trayectoria. El

método de generación de hipótesis proporciona unas altas tasas en la detección de positivos, alcanzando el 98.04% y 97.64% en condiciones nubladas y soleadas respectivamente. Además, el método propuesto alcanza mejor comportamiento en el umbralizado de intensidad que el bien conocido método propuesto en [47]. El error más frecuente que se produce en la generación de hipótesis no se debe principalmente a vehículos no detectados sino a vehículos incorrectamente enmarcados.

En cuanto a la verificación de hipótesis, los ensayos muestran una tasa de detección de positivos del 99.5%, la cual depende fuertemente del correcto enmarcado de la trasera de los vehículos. Las hipótesis correspondientes a vehículos incorrectamente enmarcadas fallan generalmente con la condición de bordes verticales. Finalmente, los resultados del sistema completo muestran un efectivo y muy fiable comportamiento, alcanzando una tasa de detección del 97.4%.

En cuanto al coste computacional, el tiempo medio de procesado alcanzado es de 248.4768 ms, el cual supone el análisis de 4 imágenes por segundo (4 fps). El sistema ha sido desarrollado y probado mediante un ordenador portátil convencional con las limitaciones que esto supone pero se espera que alcance un mayor número de imágenes analizadas por segundo mediante una unidad de procesado preparada al efecto.

Capítulo 3

CÁLCULO DE LA DISTANCIA

3.1 Introducción y estado del arte particular

Los métodos para la detección del vehículo precedente en la trayectoria pueden estar basados tanto en monovisión como en estereovisión, pero con respecto al cálculo de su distancia, la estereovisión es la única capaz de proporcionar una medida precisa [66-67]. El principal inconveniente de la estereovisión es la elevada carga computacional requerida. Además, el calibrado de estos sistemas se ve altamente afectado por las vibraciones inducidas por el ego-vehículo en movimiento.

Los sistemas basados en monovisión requieren una menor carga computacional pero no son capaces de proporcionar medidas precisas de la distancia a la que se encuentra el vehículo detectado. Además están muy condicionados por las asunciones impuestas o por los escenarios específicos de entrenamiento, los cuales limitan el funcionamiento de los sistemas.

La medición de la distancia del vehículo precedente mediante una única cámara se puede realizar de dos formas, 1) conociendo el plano de superficie (carretera) de la imagen y 2) mediante una vista frontal y conociendo la verdadera magnitud del vehículo. Ambas formas precisan de un proceso de calibrado previo del sistema. La primera requiere además la asunción de carretera plana (flat road assumption) y la segunda requiere las dimensiones reales del vehículo, lo cual no es factible ya que éstas dependen de cada marca y modelo.

Debido a estos inconvenientes, muy pocos métodos basados en monovisión han sido propuestos en el estado del arte. En [68], la profundidad de la escena es determinada a partir de gradientes de textura, desenfoque, color y bruma, usando el método de Markov Random Field (MRF) multiescala. Las imágenes y los mapas de profundidad son empleados para entrenar el modelo MRF. El uso de un conjunto finito de imágenes de entrenamiento implica que el sistema pueda operar incorrectamente en escenarios que difieran del de la fase de entrenamiento. En [69], la medición de la distancia se realiza en base al punto de contacto de las ruedas traseras del vehículo y la carretera. Este método puede subestimar la medida debido a la dificultad de identificar con precisión el punto de contacto entre las ruedas y la carretera, el cual además no corresponde con la trasera del vehículo. En [70] se explota información acerca de la apariencia de los vehículos y la distancia es determinada empleando el IPM y asumiendo carretera plana. Finalmente, en [71] se asume una anchura estandar para todos los vehículos y se usa el modelo pinhole de la cámara para determinar la distancia a la que se encuentra el vehículo.

El método que se propone en este trabajo de Tesis para calcular la distancia del vehículo precedente explota la sombra bajo el mismo, la cual es

una buena aproximación de la proyección vertical del vehículo sobre el plano de superficie. De este modo, teniendo la proyección vertical del vehículo sobre la carretera y asumiendo la condición de carretera plana, es posible estimar la distancia a la que circula el vehículo precedente mediante un proceso previo de calibrado del sistema. Este proceso consiste en establecer la relación existente entre la posición vertical de la sombra del vehículo en la imagen y la distancia a la que se encuentra el vehículo.

3.2 Estimación de la distancia

La sombra bajo un vehículo puede considerarse la proyección vertical del mismo sobre el plano de la carretera. Más teniendo en cuenta, que el método propuesto para la detección de la sombra bajo el vehículo proporciona los píxeles más oscuros de la misma (píxeles superiores de los gradientes de intensidad), los cuales corresponden con el borde inferior del marco que contiene al vehículo, el cual generalmente coincide con el punto de contacto entre las ruedas y el asfalto. De este modo, se puede considerar el borde inferior del marco conteniendo al vehículo como la línea de contacto entre el vehículo y la carretera (ver Fig. 3.1). Si se asume además la condición de tierra plana como en [70], una estimación de la distancia a la que se encuentra el vehículo puede ser realizada de una forma directa en base a la localización vertical en la imagen del borde inferior del marco del vehículo.

El procedimiento de calibrado del sistema consiste en establecer la relación existente entre la posición vertical del borde inferior del marco del vehículo en la imagen *SVP* (en píxeles) y la distancia a la que se encuentra el vehículo *Dist*. Para obtener dicha relación, el ego-vehículo se situó tras otro vehículo a distancias *Dist* conocidas comprendidas en un rango de 1 a 20m.




Figura 3.1: Variación en la imagen de la distancia del vehículo respecto a su posición vertical en la imagen *SVP*.

Para cada distancia, se capturó una imagen y se aplicó el método de detección de vehículos descrito en el capítulo 2, el cual proporciona directamente la posición vertical del borde inferior del marco del vehículo en la imagen *SVP* (ver Tabla 3.1). El proceso se llevó a cabo diez veces bajo diferentes condiciones de iluminación y con diferentes vehículos de prueba. Las distancias fueron obtenidas mediante un láser *Leica Disto Pro A* con rango de medida de 100m.

La Tabla 3.1 muestra los valores medios obtenidos de la posición vertical del borde inferior del marco del vehículo *SVP* para cada distancia *Dist*. A partir de los valores de la Tabla 3.1, obtenemos la curva exponencial aproximada que relaciona ambos parámetros (ver Fig. 3.2),

$$Dist = 89.3 \cdot e^{(-0.0027 \cdot SVP)} - 90.69 \cdot e^{(-0.0429 \cdot SVP)} \quad (19)$$

De este modo, el funcionamiento del sistema consiste en que cada vez que se detecta un vehículo, se determina la posición vertical del borde inferior del marco que contiene al mismo *SVP*, cuyo valor (píxeles) se introduce en la Ecuación (19) para dar directamente la distancia a la que se encuentra el vehículo (metros).

Tabla 3.1 Calibración de la medida *Dist SVP*.

<i>Dist</i>	<i>SVP</i>	<i>Dist</i>	<i>SVP</i>
1	30	11	92
2	52	12	92
3	66	13	92
4	74	14	93
5	79	15	93
6	83	16	93
7	86	17	94
8	88	18	93
9	90	19	94
10	91	20	94




Figura 3.2: Curva que relaciona la distancia del vehículo *Dist* y su posición vertical en la imagen *SVP*.

Sin embargo, como se puede observar en la Figura 3.2, para distancias mayores a unos 8m la variación de la posición vertical del borde inferior del marco que contiene al vehículo es muy pequeña en relación con la variación de la distancia. Esto se debe a la perspectiva de la imagen en la cual, los

planos lejanos de la escena se ven prácticamente como una perspectiva frontal y por lo tanto los objetos sobre el plano (carretera) no varían su cota (posición vertical en la imagen) por más que se alejen. De este modo, si la medida proporcionada por el método es superior a los 8m implica que el vehículo precedente está realmente circulando a más de 8m de distancia, pero el valor exacto o aproximado será muy poco fiable.

En cambio, para medidas de distancia inferiores a 8m, el método proporciona valores aproximados de la distancia del vehículo fiables. Se ha de decir que el sistema opera con imágenes de 240x320 píxeles de resolución pero la región de búsqueda que contiene a la carretera (ver Figs. 2.3(a) y 2.4(a)) es una imagen de 110x320 píxeles. Es decir, con únicamente 110 píxeles se abarca la carretera que va desde la parte delantera del ego-vehículo hasta la línea del horizonte. Con imágenes de mayor tamaño, se dispondría de más píxeles para abarcar el mismo tramo de carretera. Esto supondría que el rango válido de distancias fuera mayor a los 8m y que la medida proporcionada dentro del rango fuera más precisa. Por el contrario, el uso de una imagen con mayor resolución implicaría un tiempo de procesado más elevado. Finalmente, se ha de decir que la precisión del método de estimación de la distancia no pudo ser ensayada ni comprobada en movimiento debido a que el medidor de distancia láser empleado en el calibrado, no funciona bajo estas condiciones.

3.3 Conclusiones

Este capítulo presenta un método para la estimación de la distancia a la que circula el vehículo precedente. El método se basa en la relación existente entre la posición vertical del borde inferior del marco que contiene al vehículo

detectado y la distancia a la que éste se encuentra. Sin embargo, debido a la resolución de la imagen adoptada, el rango de medida fiable no supera los 8m de distancia. Si el vehículo circula a más de 8m, el sistema proporciona una medida de distancia superior a los 8m, pero ésta no será fiable.

El funcionamiento del método no pudo ser testado en movimiento debido a la dificultad de encontrar un método o instrumento que proporcionara bajo estas condiciones una medida fiable que validara la medida de distancia proporcionada por el método propuesto.

Capítulo 4

DETECCIÓN DE SOMBRAS

4.1 Introducción

Uno de los factores que más influyen en los sistemas ADAS basados en visión por computador son las sombras que se proyectan en la carretera y en los objetos de la escena. Las sombras pueden ocasionar en la imagen la unión aparente entre los distintos elementos, así como alterar sus características de intensidad, cromaticidad e incluso forma. De este modo, dificultan tareas esenciales como la segmentación de la carretera y la detección tanto de vehículos y peatones como de líneas de carril. Las sombras son un fenómeno indeseable para los sistemas ADAS basados en visión y su identificación es una tarea que ha sido ampliamente estudiada [72].

En el presente capítulo se propone un método basado en propiedades físicas para la detección de los bordes de las sombras en la carretera. El método no requiere calibración de la cámara y considera dos fuentes de iluminación con distribuciones espectrales distintas, la luz del sol y la luz del cielo. Como los sistemas ADAS basados en visión se caracterizan por escenas con fondos dinámicos de imagen, el método propuesto se centra en distinguir entre los bordes de las sombras y los bordes causados por un cambio de material, mediante la comparación de píxeles a ambos lados de los bordes de la imagen. Además, el método propuesto aborda separadamente las umbras y las penumbras. Para las umbras, se explotan algunas observaciones acerca de la cromaticidad de las sombras, y se proponen tres nuevas observaciones en base a la contribución de la luz del sol en la cromaticidad de la superficie. Además, se describe la variación no lineal de la cromaticidad en la penumbra y se propone un método para clasificar los bordes delimitando umbras, penumbras y regiones de la carretera no sombreadas.

El resto del capítulo está organizado como se indica a continuación. En la Sección 4.2 se exponen los métodos más relevantes para la detección de sombras. En la Sección 4.3 se describen los fundamentos de las sombras y presentamos el modelo de reflexión de la luz empleado. La Sección 4.4 trata las distribuciones espectrales de la luz del sol y de la luz del cielo, y su influencia en las umbras, en las penumbras y en la carretera no sombreada. En esta sección se presentan nuevas condiciones que satisfacen los bordes de las sombras, bien sean umbras o penumbras. La Sección 4.5 presenta el método de clasificación de los bordes de las sombras. Los resultados experimentales son expuestos en la Sección 4.5 y finalmente la Sección 4.6 se dedica a las conclusiones.

4.2 Estado del arte

Los métodos de detección de sombras se pueden clasificar en dos categorías principales [73]: métodos basados en el modelo y métodos basados en propiedades. Ambos enfoques están muy condicionados por las características de la aplicación para la que están diseñados. Algunos de los factores más determinantes son: la disponibilidad de información acerca de la escena y de la geometría de los objetos, sombras estáticas o dinámicas, iluminación natural o artificial, e imágenes estáticas o secuencias de video capturadas por una videocámara. Los métodos basados en modelos son altamente dependientes del entorno, requiriendo información acerca de la escena como la localización de la cámara, la dirección de la iluminación y la geometría de los objetos causantes de la sombras [74]. Estos métodos no son aplicables en sistemas ADAS, donde ninguna posible asunción ni de la escena ni de los objetos causantes de la sombras puede ser hecha. Por otro lado, los métodos basados en propiedades son más adecuados para aplicaciones generales. Sin embargo, muchos de ellos se centran en aplicaciones con fondo de imagen estático, donde el objetivo es detectar sombras causadas por objetos en movimiento a partir de secuencias de video captadas por una cámara fija [75,76]. En este tipo de aplicaciones, las técnicas de sustracción del fondo de la imagen son usadas para identificar las sombras por medio de la comparación de las propiedades de los píxeles del frame bajo análisis y del frame de referencia. Esta técnica tampoco es aplicable en los sistemas ADAS, ya que no hay fondo estático debido a que el vehículo está moviéndose y el escenario de la carretera está constantemente cambiando.

Los métodos basados en propiedades explotan características de las sombras como los bordes [77], la textura [78] y la composición espectral [73], la cual incluye la intensidad y la cromaticidad. El uso de la composición

espectral se basa principalmente en la asunción de que las sombras reducen la intensidad de la superficie sin apenas modificar su cromaticidad. Esta observación es efectiva para aplicaciones bajo una iluminación puramente blanca, en la cual las sombras reducen las componentes de color linealmente [73,79-80]. Sin embargo, en las aplicaciones en exteriores, la iluminación está compuesta por la luz del sol y por la luz del cielo las cuales tienen una distribución espectral (SPD) diferente. Las regiones no sombreadas de la carretera están iluminadas por la luz del sol y la luz del cielo, mientras que las regiones sombreadas lo están únicamente por la luz del cielo. Por lo tanto, la distribución espectral de la iluminación es diferente para las regiones de la carretera sombreadas y para las no sombreadas, lo que genera que su cromaticidad varíe. Con el fin de abordar este problema, los métodos basados en propiedades físicas [75] tienen en consideración el SPD de la iluminación y las propiedades de reflectividad de las superficies. Al contrario que los métodos que requieren un frame de referencia o una secuencia de imágenes, algunos métodos basados en propiedades físicas se centran en la distinción entre los bordes causados por las sombras y los causados por un cambio de material, mediante la comparación de las propiedades de los píxeles a ambos lados de los bordes de la imagen. Esta estrategia es posible en aplicaciones con fondos de imagen dinámicos como los sistemas ADAS. Los sistemas ADAS basados en visión que emplean métodos basados en el mapa de bordes (usando densidad de bordes, simetría del contorno, la transformada de Hough, para detectar las líneas, etc), pueden estar considerablemente afectados por los bordes de las sombras. Los bordes de las sombras pueden causar unión aparente entre vehículos y líneas de carril y también distorsiones en su forma y color, lo cual puede dar fácilmente como resultado el fallo del sistema. En estos casos, una imagen libre de los bordes de las sombras es muy importante para una detección de los objetos precisa.

Los primeros métodos basados en propiedades físicas están principalmente basados en la observación de que la intensidad de cada componente roja, verde y azul (RGB) de una superficie decrece a través de un borde de sombra [48]. Además, el signo del cambio (positivo o negativo) en la amplitud de las componentes RGB a través del límite de una sombra debe de ser el mismo [48]. Sin embargo, esta condición no es satisfecha cuando la distribución espectral de la luz del sol y la luz del cielo difieren significativamente [58]. Por otro lado, el efecto azulado de las sombras ha sido ampliamente explotado. El hecho de que las sombras estén únicamente iluminadas por la luz del cielo (la cual es predominantemente azul), hace que la componente normalizada de una región de la superficie sombreada sea mayor que en una región de la misma superficie no sombreada. En [83], la componente azul de las sombras es asumida como la dominante sobre las componentes verde y roja. Sin embargo, esta asunción no es siempre cierta, ya que superficies con una fuerte dominancia en la componente roja o en la verde pueden mantener su dominancia cuando están sombreadas. Además, la dominancia de la componente azul de la luz en sombras débiles y penumbras no es tan fuerte, por lo que incluso superficies poco saturadas como el asfalto pueden conservar su componente de color dominante. Debido a esto, en [84] se considera que la componente azul normalizada de una superficie sombreada aumenta mientras que su componente roja normalizada disminuye. Ambas observaciones son generalmente satisfechas en la umbra de la sombra pero no en la penumbra, debido a que ésta está iluminada por una cierta cantidad de luz del sol. Más recientemente, el método propuesto en [85] explota el hecho por el cual, cuando una superficie pasa de estar sombreada a estar no sombreada, el cambio de intensidad es mayor en las componentes roja y verde que en la azul. Esta observación es especialmente aplicable en superficies poco saturadas como el asfalto de la carretera.

Algunos métodos basados en propiedades físicas, abordan la variación cromática apoyándose en modelos de reflexión de la luz. En [58], diferentes composiciones espectrales de la luz ambiental y de la luz directa son consideradas junto con un modelo de reflexión de la luz compuesto por las componentes ambiental, difusa y especular. Este método requiere información a priori de la escena y también una estimación de la intensidad de la iluminación ambiental. El modelo de reflexión dicromática de la luz para materiales ópticamente no homogéneos, fue propuesto en [57] y también considera la tres componentes de [58]. Este método ha sido ampliamente utilizado para la detección de sombras. El DRM fue usado por primera vez para la detección de sombras en [86], donde una única fuente de iluminación es considerada. En [87], el DRM es extendido a dos fuentes de iluminación (sol y cielo). Sin embargo, este método requiere una secuencia de imágenes con información a priori de la dirección de la luz del sol y la entrada manual de varios parámetros. En [88] se propone un método para la compensación de las sombras, que establece una relación entre las tasas de las bandas de rojo y verde para cada píxel de la imagen. Este método asume que los filtros de la cámara son infinitamente estrechos y que la luz del día puede ser representada únicamente por la componente difusa del DRM.

La variación cromática es abordada en [85] mediante la integración del DRM y la comprobación del ratio de albedo espacio-temporal. Este método se centra en secuencias y requiere un frame de referencia libre de sombras, así como una fase de entrenamiento. El método propuesto en [89] identifica los bordes de las sombras mediante la combinación de la segmentación por color de la imagen y ratios de color de sus bordes. La clasificación de bordes se consigue usando un conjunto de posibles cambios de iluminación a través de un borde de sombra. En [90], los límites de las sombras son detectados mediante la comparación de la imagen RGB adquirida y la imagen invariante

a la iluminación, obtenida mediante el método propuesto en [91]. Sin embargo, este método requiere un proceso de calibración de la cámara. Más recientemente, algunos métodos basados en propiedades físicas afrontan la detección de las sombras mediante el aprendizaje de sus propiedades [75,92,93]. Sin embargo, la mayoría de ellos se centran en aplicaciones con fondo estático y requieren una larga secuencia de imágenes de entrenamiento.

En el presente capítulo se propone un método basado en propiedades físicas para la detección de los bordes de las sombras proyectadas en la carretera. El método propuesto aborda separadamente las umbras y las penumbras. Se presentan tres nuevas condiciones que satisfacen las umbras, contribuyendo así a una mejor descripción de las mismas y por tanto a una detección más fiable. Además, se muestra el comportamiento no lineal de la distribución cromática de la superficie en penumbras y se propone un método para clasificar bordes delimitando umbras, penumbras y regiones de la carretera no sombreadas.

4.3 Fundamentos físicos de las sombras: modelo de reflexión de la luz

En este trabajo se adapta el modelo dicromático DRM propuesto en [57]. El DRM describe la luz reflejada por una superficie como suma de tres componentes. Cierta cantidad de luz incidente es directamente reflejada según la ley de Fresnel por la interfase entre el aire y la superficie del material, dando lugar a brillos. Esta luz directamente reflejada es representada por la componente especular del modelo, y su distribución espectral puede ser considerada igual a la de la luz incidente [58,94]. El resto

de luz incidente penetra en la superficie, donde parte es absorbida por el material y el resto interactúa con la capa de pigmentos colorantes, produciéndose dispersión, coloración, transmisión hacia la superficie y finalmente emisión al aire. El resultado es una luz difusa emitida en todas las direcciones, la cual representa el color de la superficie y corresponde con la componente difusa del modelo.

Como la intensidad de la luz reflejada por la superficie es el producto de luz incidente y de la reflectancia de la superficie, la intensidad total de luz reflejada $I_{ref}(\lambda, p)$ en un punto p de la superficie para cierta iluminación y para cierta geometría de la perspectiva, es la suma de las intensidades correspondientes a las componentes especular y difusa [58],

$$I_{ref}(\lambda, p) = I_{incident}(\lambda, p) \cdot [\delta \cdot \rho_{specular}(\lambda, p) + (1 - \delta) \cdot \rho_{diffuse}(\lambda, p)], \quad (20)$$

donde $I_{incident}(\lambda, p)$ es la intensidad de la iluminación incidente, $\rho_{specular}(\lambda, p)$ y $\rho_{diffuse}(\lambda, p)$ son respectivamente las reflectancias especular y difusa, λ es la longitud de onda y δ es la fracción de 1 que representa la cantidad de luz incidente reflejada por la superficie del material. Por lo tanto, $(1 - \delta)$ es la cantidad de luz que penetra la superficie.

La Ecuación (20) representa la intensidad de la luz reflejada debida a una única fuente de iluminación. Sin embargo, las escenas en exteriores implican la contribución de dos tipos de iluminación, la luz del sol y la luz del cielo, las cuales presentan distinta intensidad y distinta distribución espectral.

El sol puede ser considerado como una fuente puntual emitiendo luz amarillenta. El cielo puede ser asumido como un fuente extendida de luz uniforme a lo largo del hemisferio [87] que emite luz azulada difusa. Por lo

tanto se consideran dos tipos de iluminación: incidente (luz directa del sol) y ambiental (luz difusa del cielo). Como en [85], las inter-reflexiones de luz debidas a objetos cercanos se pueden despreciar, ya que la energía decrece exponencialmente para cada inter-reflexión. Teniendo en cuenta la luz del cielo, un único término representando la componente ambiental es añadido al DRM para dar

$$I_{ref}(\lambda, p) = I_{ambient}(\lambda, p) \cdot \rho_{ambient}(\lambda, p) + I_{incident}(\lambda, p) \cdot [\delta \cdot \rho_{specular}(\lambda, p) + (1 - \delta) \cdot \rho_{diffuse}(\lambda, p)], \quad (21)$$

donde $I_{ambient}(\lambda, p)$ es la intensidad de la iluminación ambiente y $\rho(\lambda, p)$ es la reflectancia ambiental. La luz ambiental reflejada está también compuesta por las componentes especular y difusa, por lo tanto el término de la reflectancia ambiental del modelo puede ser asumido como una combinación lineal de las componentes de reflectancia especular y difusa [57,58,86]. Este trabajo se centra en el análisis de la reflexión de la luz para identificar los bordes de las sombras en la carretera. En este contexto, el estudio se limita al análisis de regiones mate, en las cuales la proporción de reflectancia especular es cercana a cero, por lo que la componente especular del modelo se puede despreciar como en [57,88]. Por lo tanto, la reflectancia es representada en un único término $\rho(\lambda, p)$ para dar

$$\begin{aligned} I_{ref}(\lambda, p) &= I_{ambient}(\lambda, p) \cdot \rho(\lambda, p) + I_{incident}(\lambda, p) \cdot \rho(\lambda, p) \\ &= [I_{ambient}(\lambda, p) + I_{incident}(\lambda, p)] \cdot \rho(\lambda, p), \end{aligned} \quad (22)$$

donde $I_{ambient}(\lambda, p)$ y $I_{incident}(\lambda, p)$ son respectivamente sustituidas por $I_{sky}(\lambda, p)$ y

$I_{sun}(\lambda, p)$. De este modo, la intensidad total de la luz reflejada $I_{ref, non-sha}(\lambda, p)$ en un punto p sobre una superficie no sombreada es

$$I_{ref, non-sha}(\lambda, p) = [I_{sky}(\lambda, p) + I_{sun}(\lambda, p)] \cdot \rho(\lambda, p), \quad (23)$$

y la intensidad de la luz reflejada por la superficie en un punto p en la sombra es

$$I_{ref, sha}(\lambda, p) = I_{sky}(\lambda, p) \cdot \rho(\lambda, p). \quad (24)$$

Con el fin de aplicar el modelo de reflexión a imágenes tomadas con una cámara digital, el modelo es extendido a la respuesta de los sensores de color de la cámara. La luz reflejada que alcanza los sensores de la cámara y la sensibilidad espectral de los mismos forman la respuesta del sensor. Para un píxel (x, y) dado de la imagen, correspondiente a un punto p de la superficie de la escena, tenemos que [95],

$$C_i(x, y) = \int_0^{\infty} I_{ref}(\lambda, p) \cdot S_i(\lambda) \cdot d\lambda, \quad (25)$$

donde $C_i \in \{R, G, B\}$ son las respuestas roja, verde y azul del sensor, y $S_i(\lambda) \in \{S_R(\lambda), S_G(\lambda), S_B(\lambda)\}$ son las sensibilidades espectrales de los sensores de la cámara de color. Si se asume que los filtros de la cámara tienen un ancho de banda infinito como en [79, 84, 88], entonces es posible representarlos por funciones impulso, las cuales están centradas en las características de los filtros. Con esta aproximación, la Ecuación (25) pasa a ser

$$C_i(x, y) = I_{ref}(\lambda_{ci}, p), \quad (26)$$

donde λ_{ci} es el centro de frecuencia del filtro del canal i . Por lo tanto, la medida del sensor para un píxel (x,y) de la imagen correspondiente a un punto de la superficie no sombreada es

$$C_i(x,y)_{non-sha} = [I_{sky}(\lambda_{ci}, p) + I_{sun}(\lambda_{ci}, p)] \cdot \rho(\lambda_{ci}, p), \quad (27)$$

dando un vector 3-D de color $C_i(x,y)_{non-sha} = (R_{non-sha}, G_{non-sha}, B_{non-sha})$. De modo similar, la respuesta para un píxel (x,y) correspondiente a un punto en la sombra es

$$C_i(x,y)_{sha} = I_{sky}(\lambda_{ci}, p) \cdot \rho(\lambda_{ci}, p), \quad (28)$$

dando un vector de color $C_i(x,y)_{sha} = (R_{sha}, G_{sha}, B_{sha})$. Por lo que se deduce que las tres componentes de color de una superficie se reducen cuando la superficie es sombreada,

$$R_{non-sha} > R_{sha}, \quad G_{non-sha} > G_{sha}, \quad B_{non-sha} > B_{sha}. \quad (29)$$

En el caso en el que la iluminación de las regiones sombreada y no sombreada tuvieran el mismo SPD, las componentes RGB de la superficie variarían linealmente para ambas regiones. Por lo tanto, las sombras reducirían únicamente la intensidad de la superficie y por lo tanto, sus componentes normalizadas RGB (*rgb*), permanecerían iguales en ambas regiones. Sin embargo, la luz del sol y la luz del cielo tienen distinto SPD lo que produce que la variación de intensidad de la Ecuación (29) no sea proporcional para las tres componentes, induciendo un cambio en la composición de color de la superficie.

4.4 Distribución espectral de la iluminación y de las sombras

4.4.1 Iluminación y características de las sombras

El sol emite luz blanca, la cual está compuesta por todos los colores del arcoiris y se propaga en ondas cuya longitud depende de su color. Por lo tanto, la luz blanca está compuesta por ondas de diferente longitud. La mayor longitud de onda corresponde con el color rojo, mientras que la más corta corresponde con el azul. Cuando la luz blanca penetra la atmósfera, es dispersada en todas las direcciones por las moléculas de los gases en el aire. Sin embargo, debido al pequeño tamaño de las moléculas, esta dispersión (Ryleigh scattering) es más efectiva con las menores longitudes de onda, las cuales corresponden con el color azul. Por este motivo el cielo adquiere un color azulado. Por otro lado, la mayor parte de la luz conteniendo el resto de longitudes de onda (desde el verde al rojo), pasa a través de la atmósfera y alcanza la superficie terrestre. La mezcla de los colores rojo y verde produce el color amarillo, por lo que la luz del sol es amarillenta, pudiendo alcanzar tonos rojizos a ciertas horas del día.

Una sombra en la carretera aparece cuando un objeto ocluye la luz directa del sol, por lo tanto, la región sombreada está únicamente iluminada por la luz azulada del cielo. En el espacio de color RGB, el azul se representa por una componente azul mayor que las componentes roja y verde. Aunque la intensidad del cielo azul puede variar a lo largo del día, su tono azul es generalmente muy puro, lo que implica unos valores de intensidad de sus componentes roja y verde muy similares (I_{Rsky}, I_{Gsky}), mientras la componente azul (I_{Bsky}) es mayor como se muestra en la Figura 4.1(a). Por lo tanto, cuando la luz del cielo ilumina una región de la carretera sombreada, se




Figura 4.1: Iluminación en exteriores: componentes RGB de (a) la luz del cielo ($I_{Rsky}, I_{Gsky}, I_{Bsky}$), (b) la luz del sol ($I_{Rsun}, I_{Gsun}, I_{Bsun}$), y (c) una región no sombreada.

puede considerar que las componentes roja y verde de la luz reflejada por la superficie son afectadas por una cantidad similar de luz, mientras que la componente azul es afectada por una cantidad de luz mayor.

Por otro lado, una región no sombreada de la carretera es iluminada tanto por la luz del sol como por la luz del cielo (ver Fig. 4.1(c)). En el espacio de color RGB, el color amarillo es el resultado de una misma cantidad de rojo y verde y una menor cantidad de azul como se muestra en la Figura 4.1(b). Sin embargo, el tono amarillo puro no puede ser asumido constante para todas las horas del día. Durante la mayor parte del día, el sol emite luz amarillenta donde las intensidades de las componentes roja y verde (I_{Rsun}, I_{Gsun}) permanecen muy similares la una respecto a la otra. El máximo equilibrio rojo-verde se produce al mediodía. Sin embargo, a medida que el sol cae en el cielo, la luz ha de atravesar un mayor espesor de atmósfera, lo que produce un incremento en la dispersión de la longitud de onda correspondiente con el

verde. De este modo, la componente de intensidad verde decrece en relación con la roja, haciendo que la luz del sol adquiriera un tono anaranjado hasta la puesta, momento en cual puede incluso alcanzar un tono rojizo. Del amanecer hasta el mediodía el proceso es similar pero al revés, la luz del sol pasa de rojiza a amarillenta.

Al contrario que la luz del cielo donde la intensidad de la componente azul es la dominante ($I_{Bsky} > I_{Rsky}$, $I_{Bsky} > I_{Gsky}$), la intensidad de la componente azul de la luz del sol es la menor ($I_{Rsun} > I_{Bsun}$, $I_{Gsun} > I_{Bsun}$).

Por lo tanto, la componente azul normalizada reflejada por la superficie decrece cuando la luz que ilumina la superficie pasa de ser luz del cielo a ser luz del cielo y luz del sol [83-85]. Esto implica que, cuando se comparan dos píxeles a ambos lados de un borde de sombra, la componente azul normalizada del píxel no sombreado $b(x_{n-sh}, y_{n-sh})$ y del sombreado $b(x_{sh}, y_{sh})$, satisfacen

$$b(x_{sh}, y_{sh}) > b(x_{n-sh}, y_{n-sh}), \quad (30)$$

donde $b(x,y) = B(x,y) / (R(x,y) + G(x,y) + B(x,y))$. Como la suma de las tres componentes rgb de un píxel es $r(x,y) + g(x,y) + b(x,y) = 1$, la disminución de la componente azul es contrarestada con un incremento medio de las componente r y g ,

$$r(x_{sh}, y_{sh}) + g(x_{sh}, y_{sh}) < r(x_{n-sh}, y_{n-sh}) + g(x_{n-sh}, y_{n-sh}). \quad (31)$$

Aunque las componentes r y g suelen aumentar, en la práctica se dan casos donde r aumenta y g disminuye ligeramente manteniendo la Ecuación (31). Dado que en la luz del sol la componente roja es igual o mayor que la verde, el incremento en r reflejado por la superficie es igual o mayor que el

incremento en g . Por lo tanto, para satisfacer la Ecuación (31), r en la región no sombreada $r(x_{n-sh}, y_{n-sh})$ es mayor que en la región sombreada $r(x_{sh}, y_{sh})$ [84],

$$r(x_{sh}, y_{sh}) < r(x_{n-sh}, y_{n-sh}), \quad (32)$$

donde $r(x, y) = R(x, y) / (R(x, y) + G(x, y) + B(x, y))$. Finalmente, comparando la iluminación de las regiones sombreadas y no sombreadas, el aumento de intensidad en las componentes roja y verde es mayor que en la azul, lo que hace que las componentes RGB de la superficie satisfagan [85]

$$\begin{aligned} \frac{R(x_{n-sh}, y_{n-sh})}{R(x_{sh}, y_{sh})} &> \frac{B(x_{n-sh}, y_{n-sh})}{B(x_{sh}, y_{sh})}, \\ \frac{G(x_{n-sh}, y_{n-sh})}{G(x_{sh}, y_{sh})} &> \frac{B(x_{n-sh}, y_{n-sh})}{B(x_{sh}, y_{sh})}. \end{aligned} \quad (33)$$

Una vez mostradas la principales observaciones del estado del arte, se proponen relaciones adicionales para caracterizar mejor las sombras, con el fin de minimizar los posibles errores en la clasificación de bordes debidos a cambios de material como bordes de sombra.

4.4.2 Características de las sombras propuestas

1º Observación

De acuerdo con el modelo de reflexión de la luz propuesto, cuando comparamos dos píxeles a ambos lados de un borde de sombra, la contribución de la luz del sol en el píxel no sombreado viene dada por

$$C_i(x_{n-sh}, y_{n-sh})_{sun} = C_i(x_{n-sh}, y_{n-sh}) - C_i(x_{sh}, y_{sh}), \quad (34)$$

proporcionando un vector de color $C_i(x_{n-sh}, y_{n-sh})_{sun} = (R_{sun}, G_{sun}, B_{sun})$.

Una primera relación es propuesta teniendo en cuenta únicamente las componentes roja y verde de la iluminación. El tono de la luz del cielo es generalmente muy puro por lo que las intensidades de las componentes roja y verde presentan unos valores muy similares ($I_{Rsky} \approx I_{Gsky}$). De este modo, una relación entre las reflectancias roja y verde de la superficie puede ser obtenida a partir de un punto de la superficie sombreada. A partir de la Ecuación (28), las componentes roja y verde de un píxel en la sombra son

$$R_{sha} = I_{Rsky} \cdot \rho_R, \quad G_{sha} = I_{Gsky} \cdot \rho_G, \quad (35)$$

donde dividiendo ambas expresiones y asumiendo $I_{Rsky} = I_{Gsky}$, las reflectancias roja y verde quedan relacionadas de la forma

$$\frac{R_{sha}}{G_{sha}} = \frac{I_{Rsky}}{I_{Gsky}} \cdot \frac{\rho_R}{\rho_G} \Rightarrow \frac{\rho_R}{\rho_G} = \frac{R_{sha}}{G_{sha}}. \quad (36)$$

Por otro lado, la contribución de la luz del sol en las componentes roja y verde de un píxel correspondiente a un punto de la superficie no sombreada es obtenida a partir de la Ecuación (27), haciendo $I_{sky}(\lambda_{ci}, p) = 0$,

$$R_{sun} = I_{Rsun} \cdot \rho_R, \quad G_{sun} = I_{Gsun} \cdot \rho_G, \quad (37)$$

donde dividiendo ambas expresiones y sustituyendo la división de las reflectancias por la Ecuación (36), se tiene que

$$\frac{R_{sun}}{G_{sun}} = \frac{I_{Rsun}}{I_{Gsun}} \cdot \frac{\rho_R}{\rho_G} \Rightarrow \frac{I_{Rsun}}{I_{Gsun}} = \frac{R_{sun}}{G_{sun}} \cdot \frac{G_{sha}}{R_{sha}}. \quad (38)$$

Como la luz del sol no suele alcanzar tonos verdosos, su componente roja generalmente es igual o mayor que la componente verde ($I_{Rsun} \geq I_{Gsun}$). Por lo tanto, cuando comparamos dos píxeles a ambos lados de un borde de sombra, la siguiente condición es satisfecha:

$$\frac{R_{sun}}{G_{sun}} \cdot \frac{G_{sha}}{R_{sha}} \geq 1, \quad (39)$$

donde $R_{sun} = R_{non-sha} \cdot R_{sha}$ and $G_{sun} = G_{non-sha} \cdot G_{sha}$.

2º Observación

Una segundo conjunto de relaciones es propuesto teniendo en cuenta la similitud de las componentes roja y verde de la iluminación. Tanto para la luz del cielo como para la luz del sol, las intensidades de las componentes roja y verde son cercanas la una respecto a la otra (ver Fig. 4.1), mientras que ambas difieren considerablemente respecto a la intensidad de la componente azul.

Por lo tanto, la relación entre las componentes roja y verde de la luz reflejada por la superficie iluminada por la luz del cielo, es cercana a la relación entre las mismas componentes de la superficie iluminada por la luz del sol. Sin embargo, las intensidades de las componentes roja y azul difieren considerablemente en magnitud y en signo, tanto en la distribución de la luz del cielo como en la de la luz del sol ($I_{Rsky} < I_{Bsky}, I_{Rsun} > I_{Bsun}$) (ver Fig. 4.1). De este modo, la relación rojo-azul de la superficie iluminada por la luz del cielo es considerablemente diferente a dicha relación de la superficie iluminada únicamente por el sol. Por lo tanto, cuando se comparan dos píxeles a ambos

lados de un borde de sombra, el cambio en la proporción de las componentes roja-verde debida a la luz del cielo y a la luz del sol es menor que el cambio en la relación roja-azul. Éste razonamiento es válido con las relaciones rojo-verde, verde-azul de la superficie,

$$\begin{aligned} \left| \frac{R_{sha}}{G_{sha}} - \frac{R_{sun}}{G_{sun}} \right| &< \left| \frac{R_{sha}}{B_{sha}} - \frac{R_{sun}}{B_{sun}} \right|, \\ \left| \frac{G_{sha}}{R_{sha}} - \frac{G_{sun}}{R_{sun}} \right| &< \left| \frac{G_{sha}}{B_{sha}} - \frac{G_{sun}}{B_{sun}} \right|. \end{aligned} \quad (40)$$

Ambas restricciones son especialmente aplicables en superficies neutras como el asfalto de la carretera, el cual tiene valores similares de reflectancia para cada componente ($\rho_R \approx \rho_G \approx \rho_B$) y por tanto su distribución RGB es prácticamente proporcional a la distribución de la iluminación.

3º Observación

La siguiente relación es propuesta teniendo en cuenta la saturación de la superficie iluminada. La saturación es una característica que en el estado del arte crea cierta controversia [96]. Algunos autores consideran que las sombras reducen la saturación de la superficie [79], mientras que otros asumen lo contrario [97]. Sin embargo, en la práctica ambas observaciones son posible, especialmente en superficies neutras como el asfalto de la carretera, donde la saturación de la superficie es básicamente debida a la saturación de la iluminación. La saturación de una región de la carretera no sombreada es el resultado de las saturaciones inducidas por la luz del cielo y por la luz del sol. Pero como las distribución RGB de ambas iluminaciones son opuestas (el amarillo y el azul son colores complementarios), cuando

ambas se combinan, la saturación de luz combinada se compensa en gran medida. La cantidad de saturación compensada depende no solo de las saturaciones de ambas luces, sino que también depende de sus intensidades. Aunque la intensidad de la luz del sol es mayor que la intensidad de la luz del cielo, su diferencia varía para cada día y en función de la hora del día, lo que puede hacer que la saturación de la luz combinada sea mayor, igual o menor que la saturación de la luz del cielo.

Sin embargo, una nueva consideración puede ser hecha. En la práctica, la saturación de una superficie neutra iluminada únicamente por la luz del cielo es menor que la saturación de dicha superficie debida a la luz del sol.

Se asume la hipotética distribución RGB del asfalto de la carretera mostrada en la Fig. 4.2, en la cual los valores de la mayor y de la menor componente debidas a la luz del cielo y a la luz del sol son iguales ($R_{sha}=B_{sun}, B_{sha}=R_{sun}$). De acuerdo al espacio de color HSI (*Hue, Saturation, Intensity*), la intensidad y la saturación de una superficie vienen dadas por

$$I = \frac{R+G+B}{3}, \quad Sat = 1 - \frac{\min(R,G,B)}{I}. \quad (41)$$

Por lo tanto, la saturación de la superficie debida a la luz de cielo Sat_{sha} y a la luz del sol Sat_{sun} son respectivamente,

$$Sat_{sha} = 1 - \frac{R_{sha}}{I_{sha}}, \quad Sat_{sun} = 1 - \frac{B_{sun}}{I_{sun}}, \quad (42)$$

donde $I_{sha} = (R_{sha} + G_{sha} + B_{sha})/3$ y $I_{sun} = (R_{sun} + G_{sun} + B_{sun})/3$.




Figura 4.2: Distribuciones RGB de una superficie acromática debidas a la luz del cielo (a), y a la luz del sol (b).

Como se puede observar, para ambas distribuciones los valores de la intensidad de las componentes roja y verde son iguales por lo que tienen un mayor peso en la intensidad total de ambos colores. Como ambas distribuciones son opuestas, la intensidad de la superficie debida a la luz del cielo es menor que la intensidad de la superficie debida a la luz del sol ($I_{sha} < I_{sun}$). Por lo tanto, el divisor de R_{sha}/I_{sha} en la Ecuación (42) es mayor que B_{sun}/I_{sun} , lo que causa que la saturación de la superficie debida a la luz del cielo sea menor que la saturación de dicha superficie debida a la luz del sol ($Sat_{sha} < Sat_{sun}$).

En este hipotético caso, la diferencia entre la intensidad de la superficie debida a la luz del cielo y la debida a la luz del sol es muy pequeña, sin embargo en la práctica, la intensidad de la superficie debida a la luz del sol es mucho mayor que la debida a la luz del cielo [76]. Además, cuanto mayor es la intensidad de la luz del cielo, mayor es la relación $\Delta I_{sun}/I_{sun}$ y por lo

tanto, B_{sun}/I_{sun} disminuye, lo que genera que la saturación de la carretera debida a la luz del sol sea incluso mayor. De este modo, cuando se comparan dos píxeles a ambos lados de un borde de sombra, las contribuciones de la luz del cielo y de la luz de sol en la superficie satisfacen que,

$$Sat(x_{sh}, y_{sh})_{sha} < Sat(x_{n-sh}, y_{n-sh})_{sun}. \quad (43)$$

Para superficies sombreadas en las cuales las componentes roja y verde son mayores que la componente azul ($R_{sha} > B_{sha}, G_{sha} > B_{sha}$), la condición de la Ecuación (43) es evidente, ya que el incremento de las componentes roja y verde es mayor que el incremento de la componente azul cuando se compara la región sombreada y la no sombreada.

Las tres observaciones propuestas en el presente trabajo (Eqs. (39)-(40) y (43)) junto con las observaciones propuestas en el estado de arte (Eqs. (30)-(33)), conducen a una robusta caracterización de las sombras. Sin embargo, presentan un inconveniente al identificar los bordes de las sombras. Estas relaciones describen correctamente la variación de la cromaticidad de la umbra de las sombras, pero fallan al modelar la penumbra.

4.4.3 Descripción de la penumbra. Características propuestas.

La umbra es la región de la sombra donde la luz del sol está totalmente ocluida, por lo tanto está únicamente iluminada por la luz del cielo. La penumbra es una región de transición entre la umbra y la superficie no sombreada, la cual está iluminada por la luz del cielo y parcialmente iluminada por la luz del sol. Por lo tanto, cuando un borde de la imagen

separa una penumbra de la superficie no sombreada, la asunción inicial de que únicamente la luz del cielo ilumina la sombra no es satisfecha. Este hecho afecta tanto a bordes de sombra débiles como a aquellos bien definidos y una posible solución consistiría en evitar las penumbras comparando píxeles suficientemente alejados del borde de la sombra, de modo que correspondieran a la región en umbra y a la región no sombreada. Sin embargo, esta estrategia implica que las sombras tengan umbra, lo cual no es siempre cierto, especialmente en escenas de carretera urbana, donde las sombras pueden ser causadas por elementos de la escena delgados como ramas de los árboles, señales de tráfico, postes de la luz, etc, las cuales pueden estar compuestas únicamente por penumbra.

La Figura 4.3(b) ilustra la sombra causada por un elemento delgado. Debido a la geometría del elemento, cualquier punto de la región sombreada es iluminado por una cierta cantidad de luz del sol y por tanto la sombra no tiene umbra. Las Figs. 4.4(a) y 4.4(b) muestran respectivamente dos escenas




Figura 4.3. Penumbra: (a) Umbra S_u , penumbra desde S_{p1} hasta S_{pn} y región no sombreada S_{n-s} , y (b) toda la región sombreada causada por un elemento delgado está en penumbra, ya que todos los puntos están parcialmente iluminados por la luz del sol.

típicas de carretera en presencia de sombras y sus respectivos mapas de bordes. Las Figs. 4.4(c) y 4.4(d) muestran respectivamente sus respectivas componentes normalizadas azul y roja. En ambas escenas, las sombras causadas por elementos suficientemente gruesos como los vehículos (escena izquierda) o ramas densas (escena derecha) están compuestas por una región de umbra y por una región de penumbra que las rodea. Por otro lado, las sombras causadas por elementos suficientemente delgados como las ramas de los árboles (ambas escenas) o el semáforo (escena derecha), no tienen umbra, por lo que toda la sombra es penumbra. Se puede apreciar como la componente azul normalizada es claramente mayor en las regiones de umbra que en la carretera no sombreada, mientras que la componente roja



Figura 4.4. Dos escenas en presencia de sombras: (a) imagen original, (b) mapa de bordes obtenido mediante el operador Canny y las correspondientes componentes normalizadas (c) azul y (d) roja.

normalizada es menor, satisfaciendo las condiciones soportadas en las Eqs. (30) y (32). Sin embargo, para las penumbras ninguna de las condiciones es satisfecha. La componente azul es de hecho más pequeña en la penumbra que en la superficie no sombreada mientras que la componente roja es mayor. Por lo tanto, de acuerdo con las ecuaciones (30) y (32), los bordes de la imagen delimitando penumbras y carretera no sombreada serían clasificados como bordes debidos a un cambio de material, en lugar de bordes de sombra.

En las penumbras, la intensidad de la luz del sol incidente aumenta desde la umbra hasta la región no sombreada (ver Fig. 4.3(a)), por lo tanto, las componentes RGB de la superficie aumentan. Sin embargo, este aumento no es constante, lo que hace que las componentes normalizadas rgb de la superficie varíen no linealmente. La Fig. 4.5(a) muestra una región de la carretera compuesta por regiones no sombreadas, regiones en umbra y regiones en penumbra, y sirve para ilustrar el comportamiento de las componentes rgb a lo largo de la penumbra. La Fig. 4.5(b) representa las componentes roja y verde de los píxeles de la región en función de la componente azul. (Nota: el eje horizontal de las gráficas en la Fig. 4.5 no es la anchura física de la penumbra sino la anchura de su componente de color azul, desde la intensidad de azul de los píxeles en umbra B_u hasta la intensidad de azul de los píxeles de la región no sombreada B_{n-s}). Finalmente, las Fig. 4.5(c) y 4.5(d) muestran respectivamente la variación de las componentes normalizadas rgb y de la saturación de la superficie a lo largo de la penumbra. Como se puede observar en la Fig. 4.5(b), las componentes RGB de la superficie aumentan desde la umbra (R_u, G_u, B_u) hasta la región no sombreada ($R_{n-s}, G_{n-s}, B_{n-s}$). Sin embargo, esta variación no es lineal a lo largo de la penumbra y dos secciones diferentes pueden ser identificadas. La primera sección va desde la umbra S_u donde la luz incidente del sol es nula, hasta un punto intermedio S_{pm} donde una cierta cantidad de luz del sol




Figura 4.5. (a) Región de la carretera compuesta por asfalto no sombreado, umbras y penumbras. A lo largo de la penumbra: (b) componentes roja y verde respecto a la azul, (c) componentes normalizadas rgb y (d) saturación.

ilumina la superficie. Las componentes roja y verde incrementan considerablemente con respecto a la azul, causando el cambio en la proporción RGB del cromaticidad de la superficie. En esta primera sección, la disminución en la componente azul normalizada alcanza un valor mínimo en el punto S_{pm} (ver Fig. 4.5(c)). Esta disminución es compensada básicamente por la componente roja normalizada, mientras que la disminución de la componente verde normalizada es menor. Por otro lado, la saturación de la superficie decrece gradualmente desde la saturación inducida únicamente por la luz del cielo en la umbra S_u . Como la intensidad de la luz del sol aumenta, la saturación de la superficie es compensada, alcanzando un valor mínimo en el punto S_l (ver Fig. 4.5(d)).

La segunda sección de la penumbra va desde el punto S_{pm} hasta el punto de la región no sombreada S_{n-s} , el cual está completamente iluminado por la luz del sol. A pesar del aumento en la intensidad de la luz del sol, las pendientes de las componentes roja y verde respecto a la componente azul, pasan a ser muy similares, alcanzando valores incluso menores a 45° , lo cual hace que las intensidades de las componentes roja y verde disminuyan respecto a la intensidad de la componente azul. Por lo tanto, la componente azul normalizada experimenta un incremento gradual desde el punto S_{pm} hasta el punto de la región no sombreada S_{n-s} , lo cual es compensado con la disminución de las componentes normalizadas roja y verde.

La variación de la componente azul normalizada no es decreciente a lo largo de la penumbra y su valor mínimo no es debido a la máxima intensidad de la luz del sol incidente sino a una intensidad menor de ésta. Por lo tanto, en la penumbra existe un rango $S_{l,n-s} \in [S_l, S_{n-s}]$, donde la componente azul normalizada es menor que en la región no sombreada, mientras que la componente roja es mayor (ver Fig. 4.5(c)). De este modo, cuando se

comparan dos píxeles a ambos lados de un borde de sombra y el más oscuro cae en la sección $S_{l,n-s}$ mientras que el píxel menos oscuro cae en la región no sombreada, la componente azul normalizada del primero $b(x_{sh}, y_{sh})$ es menor o igual que la del segundo $b(x_{n-sh}, y_{n-sh})$,

$$b(x_{sh}, y_{sh}) \leq b(x_{n-sh}, y_{n-sh}), \quad (44)$$

y la componente roja normalizada es igual o mayor,

$$r(x_{sh}, y_{sh}) \geq r(x_{n-sh}, y_{n-sh}). \quad (45)$$

Por otro lado, la amplitud entre las componentes normalizadas r y b a lo largo de $S_{l,n-s} \in [S_l, S_{n-s}]$ es igual o mayor que la amplitud de la región no sombreada en el punto S_{n-s} , mientras que la intensidad de la superficie es menor (ver Fig. 4.5(c)). Por lo tanto, como se puede apreciar en la Fig. 4.5(d), la saturación de un píxel $Sat(x_{sh}, y_{sh})$ que cae en $S_{l,n-s} \in [S_l, S_{n-s}]$ es igual o mayor que la saturación de la región de la carretera no sombreada $Sat(x_{n-sh}, y_{n-sh})$,

$$Sat(x_{sh}, y_{sh}) \geq Sat(x_{n-sh}, y_{n-sh}). \quad (46)$$

Esta variación no lineal a lo largo de la penumbra es confirmada en imágenes adquiridas en diferentes días soleados, a diferentes horas y en diferentes carreteras. Las pendientes de las relaciones roja-azul y verde-azul pueden variar, así como la anchura de la sección $S_{l,n-s} \in [S_l, S_{n-s}]$. En días totalmente despejados, el incremento de las componentes roja y verde respecto a la componente azul es muy fuerte, lo que hace a la componente azul normalizada disminuir considerablemente, alcanzando el valor mínimo S_{pm} en un punto intermedio del azul de la penumbra. Por lo tanto, la sección $S_{l,n-s} \in [S_l, S_{n-s}]$ es considerablemente más ancha. Por otro lado, en días

parcialmente soleados en los cuales el sol está levemente cubierto, las pendientes de las relaciones roja-azul y verde-azul aumentan gradualmente y el punto S_{pm} se desplaza hacia la derecha, acortando así la sección $S_{l,n-s} \in [S_l, S_{n-s}]$. En estas condiciones, la componente azul normalizada disminuye gradualmente y el valor mínimo en el punto S_{pm} puede incluso no excede el valor de la región no sombreada de la carretera.

Por lo tanto, se puede concluir que las características cromáticas de las umbras y de las penumbras son diferentes, por lo cual su identificación debe llevarse a cabo separadamente.

4.4.4 Identificación de los bordes de las sombras

En la práctica, un borde de sombra puede separar la carretera no sombreada de una umbra o de una penumbra, así como puede separar una umbra de una penumbra.

Cuando el píxel oscuro (x_{sh}, y_{sh}) de la comparación corresponde con un punto dentro del rango $S_{u,l} \in [S_u, S_l]$ de la penumbra, las restricciones de cromaticidad (Eqs. (30)-(33), (39), (40) y (43)) son satisfechas independientemente de si el píxel claro (x_{n-sh}, y_{n-sh}) , pertenece a la carretera no sombreada o a un punto adjacente de la propia penumbra (ver Fig. 4.5(c)). Por otro lado, las relaciones de las Eqs. (44)-(46) son satisfechas cuando el píxel oscuro de la comparación corresponde con un punto dentro del rango $S_{l,n-s} \in [S_l, S_{n-s}]$ de una penumbra, mientras el píxel claro pertenece a una región de la carretera no sombreada S_{n-s} .

El punto S_l de la penumbra delimita ambos rangos y puede ser aproximado como el punto de intersección entre la curva formada por las

componentes roja-azul y la línea m , la cual pasa por el punto (R_{n-s}, B_{n-s}) y el origen (ver Fig. 4.5(b)). La relación de las componentes roja-azul de un píxel en el punto S_I de la penumbra es igual a dicha relación de un punto de la carretera no sombreada. Por lo tanto, la relación de las componentes roja-azul de los píxeles a ambos lados de un borde, determina si el píxel corresponde a un potencial borde que separa una región no sombreada de una umbra o de una penumbra, o si por otro lado separa una umbra de una penumbra. De este modo, dados dos píxeles a ambos lados de un borde de sombra, si el píxel oscuro (x_{sh}, y_{sh}) pertenece a un punto del rango $S_{u,l} \in [S_u, S_l]$, la relación de sus componentes roja-azul es menor que dicha relación del píxel claro (x_{n-sh}, y_{n-sh}) ,

$$\frac{R(x_{sh}, y_{sh})}{B(x_{sh}, y_{sh})} < \frac{R(x_{n-sh}, y_{n-sh})}{B(x_{n-sh}, y_{n-sh})}. \quad (47)$$

Por el contrario, si el píxel oscuro pertenece a un punto del rango $S_{l,n-s} \in [S_l, S_{n-s}]$ de la penumbra y el píxel claro pertenece a un punto de la región no sombreada, la relación entre las componentes roja-azul del primero es igual o mayor que dicha relación del píxel claro y por lo tanto, la Eq. (47) no es satisfecha.

La relación de las componentes roja-azul de la Eq. (47) es la misma que la restricción para borde de sombra de la Eq. (32). Esta relación no es satisfecha en bordes que separan un punto perteneciente al rango $S_{l,n-s} \in [S_l, S_{n-s}]$ de la penumbra y un punto perteneciente a la carretera no sombreada, lo que hace esta relación muy útil para distinguir los diferentes tipos de borde de sombra.

4.5 Algoritmo de clasificación de los bordes de las sombras

El algoritmo para la detección de bordes de sombra propuesto comprende dos etapas. En la primera etapa, el mapa de bordes $C(x,y)$ de la imagen a color adquirida es extraído aplicando separadamente a los tres canales RGB el operador Canny [98], seguido de una operación de conexión OR sobre los tres mapas resultantes. En la segunda etapa, el mapa de bordes es barrido de arriba abajo y el análisis de identificación del borde de sombra es aplicado a cada píxel del mapa de bordes.

En el primer paso de esta segunda etapa, los píxeles oscuro $C_i(x_{sh}, y_{sh})$ y claro $C_i(x_{n-sh}, y_{n-sh})$ a ambos lados del píxel bajo evaluación $C_i(x,y)$ son obtenidos a partir de la orientación de su gradiente,

$$\theta_i(x,y) = \arctan\left(\frac{G_x}{G_y}\right), \quad (48)$$

donde G_x y G_y son respectivamente los gradientes vertical y horizontal de $C_i(x,y)$ y vienen dados por

$$G_x = I(x+1,y-1) + 2I(x+1,y) + I(x+1,y+1) - I(x-1,y-1) - 2I(x-1,y) - I(x-1,y+1), \quad (49)$$

$$G_y = I(x-1,y+1) + 2I(x,y+1) + I(x+1,y+1) - I(x-1,y-1) - 2I(x,y-1) - I(x+1,y-1), \quad (50)$$

y donde $I(x,y) = (R(x,y) + G(x,y) + B(x,y))/3$.

La Tabla 4.1 muestra las coordenadas del píxel oscuro y del píxel claro a ambos lados del píxel de borde $C_i(x,y)$ en función de la orientación $\theta_i(x,y)$ de este último. Una primera condición es aplicada para comprobar la restricción de intensidad propuesta en la Eq. (29). Por lo tanto, el píxel de borde bajo evaluación $C_i(x,y)$ es un candidato a ser un píxel del borde de una sombra, si la intensidad de cada una de las RGB componentes del píxel oscuro es menor que las respectivas componentes RGB del píxel claro. En cualquier otro caso, el píxel $C_i(x,y)$ es clasificado como píxel de un borde correspondiente a un cambio de material.

El segundo paso de esta segunda etapa consiste en clasificar el píxel de borde bajo evaluación $C_i(x,y)$ como candidato a separar una región de la carretera no sombreada de una región en umbra o de una región en penumbra, o si por otro lado es candidato a separar una región en umbra de una penumbra. Con este propósito, si la Eq. (47) es satisfecha, el píxel de borde $C_i(x,y)$ pasa a ser candidato a separar una región no sombreada de una región en umbra o de un punto perteneciente al rango $S_{u,l} \in [S_u, S_l]$ de una

Table 4.1. Selección de los píxeles a ambos lados del borde $C_i(x,y)$

Orientación ($^\circ$) $\theta_i(x,y)$	Píxel oscuro(x_{sh},y_{sh})	Píxel claro (x_{n-sh},y_{n-sh})
$337.5^\circ < \theta_i(x,y) \leq 22.5^\circ$	$(x,y-2)$	$(x,y+2)$
$22.5^\circ < \theta_i(x,y) \leq 67.5^\circ$	$(x+2,y-2)$	$(x-2,y+2)$
$67.5^\circ < \theta_i(x,y) \leq 112.5^\circ$	$(x+2,y)$	$(x-2,y)$
$112.5^\circ < \theta_i(x,y) \leq 157.5^\circ$	$(x+2,y+2)$	$(x-2,y-2)$
$157.5^\circ < \theta_i(x,y) \leq 202.5^\circ$	$(x,y+2)$	$(x,y-2)$
$202.5^\circ < \theta_i(x,y) \leq 247.5^\circ$	$(x-2,y+2)$	$(x+2,y-2)$
$247.5^\circ < \theta_i(x,y) \leq 292.5^\circ$	$(x-2,y)$	$(x+2,y)$
$292.5^\circ < \theta_i(x,y) \leq 337.5^\circ$	$(x-2,y-2)$	$(x+2,y+2)$

penumbra. En caso contrario, el píxel de borde $C_A(x,y)$ pasa a ser candidato a separar una región no sombreada de un punto que pertenece al rango $S_{l,n-s} \in [S_l, S_{n-s}]$ de una penumbra.

Para el primero de los casos, el píxel $C_A(x,y)$ es finalmente verificado como píxel perteneciente al borde de una sombra si satisface las restricciones de cromaticidad para las sombras soportadas en las Eqs. (30), (32), (38), (39) y (43). Para el segundo de los casos, el píxel $C_A(x,y)$ es entonces verificado como píxel perteneciente al borde de una sombra si satisface las restricciones de cromaticidad para las sombras soportadas en las Eqs. (44)-(46). En cualquier otro caso, el píxel $C_A(x,y)$ es clasificado como píxel de un borde correspondiente a un cambio de material.

4.6 Resultados

Los experimentos fueron llevados a cabo con secuencias de imagen adquiridas mediante la cámara Trust Widescreen HD WebCam, equipada con 8 bits de profundidad de píxel y balance de blancos así como tiempo de exposición automáticos, la cual proporcionó imágenes a color de 240x320 píxeles de resolución. Un total de 6,600 imágenes de carretera en 22 conjuntos de 300 frames fueron adquiridos en tráfico urbano bajo diferentes condiciones soleadas. Las imágenes consistían en escenas de tráfico en presencia de una amplia variedad de sombras en la carretera. Las imágenes fueron adquiridas y procesadas en Matlab® con un ordenador portátil convencional.

La Figura 4.6 muestra algunos ejemplos de los resultados de la detección de bordes de sombra en escenas de tráfico complicadas. Con el fin de mostrar el comportamiento real del algoritmo propuesto, no se ha aplicado ningún tipo de filtro al mapa de bordes resultante.

Como se observa en la Fig. 4.6, el detector de bordes de sombra propuesto identifica correctamente y elimina los bordes debidos a las sombras proyectadas en la carretera, mientras que aquellos bordes causados por los distintos elementos de las escenas son correctamente clasificados como bordes debidos a un cambio de material y por lo tanto, permanecen en el mapa de bordes. El resultado son mapas de bordes prácticamente libres de píxeles debidos a los bordes de las sombras. El algoritmo propuesto demuestra gran robustez, ya que detecta tanto bordes de sombra afilados como suaves. La detección de bordes de sombra fuertes (umbra-carretera no sombreada) resulta excelente (ver Figs. 4.6(a), 4.6(c)), mientras que la detección de bordes de sombra suave (umbra-penumbra y penumbra-carretera no sombreada) es bastante buena (ver Figs. 6(b), 6(d), 6(f)).

Las Figuras 4.6(d) y 4.6(g) también muestran un buen comportamiento en la detección de bordes de sombra en las aceras, las cuales son generalmente superficies de color poco saturado. En la Fig. 4.6(c) se puede apreciar que algunos píxeles del borde de sombra proyectado en la hierba no son correctamente detectados. Esto no se debe a la cromaticidad de la superficie sino a que en algunos casos, la hierba es una superficie muy texturizada en la cual, la comparación de los píxeles a ambos lados del borde puede no resultar satisfactoria. La Fig. 4.6 también muestra el buen comportamiento en la clasificación de bordes debidos a cambios de material, incluso cuando la región de la escena donde se producen está sombreada. La acumulación de restricciones basadas en las características de cromaticidad de las sombras, contribuye en una buena clasificación de las mismas, reduciendo la posibilidad de errores en la clasificación de los bordes debidos a cambios de material.




Figura 4.6. Ejemplos de los resultados del método. Para cada ejemplo, (arriba) imagen original, (Medio) su mapa de bordes, y (abajo) el mapa de bordes resultante tras detectar y eliminar los bordes de sombra.

Sin embargo, dos errores pueden suceder. En primer lugar, cuando las líneas amarillas pintadas en el asfalto son muy suaves (generalmente debido al desgaste de la vía), los bordes línea-asfalto que crean en la imagen pueden satisfacer las restricciones de los bordes de sombra, lo que conduce a un error en su clasificación. Por otro lado, el segundo error ocurre en la clasificación de los bordes de sombra bajo los vehículos, las cuales generalmente son muy oscuras y sus componentes RGB presentan valores muy bajos, haciendo de la cromaticidad de la superficie una característica inestable cuando se emplean las componentes normalizadas. Sin embargo, este error en la clasificación es positivo, ya que el borde de la sombra bajo el vehículo corresponde con el borde inferior del contorno del mismo (ver Fig. 4.6). Finalmente, cabe destacar que la precisión de la detección depende de la precisión del operador empleado para extraer los bordes de la imagen (Canny).

Con el fin de evaluar cuantitativamente el comportamiento del algoritmo propuesto, los mapas “ground-truth” son manualmente generados para un conjunto de 50 imágenes. Los mapas “ground-truth” son obtenidos de los mapas de bordes, donde los bordes debidos a las sombras y los bordes debidos a cambios de material son manualmente separados en dos mapas “ground-truth”, como se muestra en la Fig 4.7.

Una evaluación cuantitativa es realizada comparando los mapas de bordes obtenidos mediante el método propuesto con los mapas “ground-truth”. La evaluación consiste en el cálculo de la tasa de detección de bordes de sombra SDR y la precisión de la detección de bordes de sombra SDA [99],

$$SDR = \frac{TP}{TP + FP} \cdot 100, \quad SDA = \frac{TP}{TP + FN} \cdot 100, \quad (51)$$

donde TP (positivos) es el número de píxeles correctamente detectados como




Figura 4.7. Ejemplo: (a) Imágen original, (b) mapa de bordes, (c) “ground truth” de los bordes de sombra y (d) “ground truth” de los bordes debidos a un cambio de material.

pertenecientes a un borde de sombra, FN (falsos negativos) es el número de píxeles debidos a bordes de sombra incorrectamente clasificados como bordes debidos a un cambio de material y FP (falsos positivos) es el número de píxeles debidos a un cambio de material incorrectamente clasificados como bordes de sombra.

El comportamiento del algoritmo propuesto es además comparado con cuatro métodos del estado del arte basados en propiedades físicas de las sombras:

1. El **método A1** consiste en la acumulación de las ya conocidas restricciones de cromaticidad (Eqs. (29), (30), (32) y (33)).
2. El **método A2** está basado en el método propuesto en [54] para la atenuación de sombras en la carretera. Este método requiere de un umbral de intensidad que nosotros obtenemos manualmente para las 60 imágenes.
3. El **método A3** es el método propuesto en [85], el cual emplea reducción de intensidad de las componentes RGB (Eq. 10), la tasa de azul (Eq. 33) y la tasa de albedo. Este método está diseñado para detectar sombras en secuencias de imágenes, donde un frame inicial sin sombras es requerido. La implementación del método se adapta a escenas con fondos dinámicos, comparando píxeles a ambos lados de los bordes de imagen en lugar de comparar los píxeles del frame de referencia con los correspondientes píxeles del frame bajo análisis. Con el fin de aplicar la tasa de albedo, se emplea los píxeles vecinos de los dos píxeles a ambos lados del píxel bajo evaluación.
4. El **método A4** se basa en el método propuesto en [90], el cual extrae los bordes de las sombras comparando los bordes de la imagen original con los de la imagen invariante ante la iluminación. Un borde es clasificado como correspondiente a una sombra, si el píxel de la imagen original corresponde con un borde fuerte y el de la imagen invariante es débil, o si el píxel en ambas imágenes es fuerte pero sus orientaciones son diferentes. Como en [90], los umbrales τ_1, τ_2, τ_3 son considerados 0.4, 0.1 and $\pi/4$, respectivamente. La calibración de la cámara es realizada por el método de la mínima entropía propuesto en [80], usando 15 frames. Se obtiene una dirección característica para nuestra cámara igual a $\theta=73.2^\circ$.

La Figura 4.8 muestra los mapas de bordes resultantes del ejemplo en la Fig. 4.7, obtenidos usando los cinco métodos y la Tabla 4.2 muestra los

resultados cuantitativos obtenidos para el conjunto de 50 imágenes. La Tabla 4.2 muestra que el método propuesto en este trabajo alcanza mejor comportamiento tanto en la tasa de detección de bordes de sombra (96.3%) como en la precisión de la detección (93.7%). La Fig. 4.8 muestra que el método propuesto se comporta muy bien detectando bordes umbra-carretera no sombreada (bordes de las sombras de los coches aparcados), bordes umbra-penumbra (parte de abajo y a la izquierda de la escena) y bordes penumbra-carretera no sombreada (centro y parte de debajo de la escena). Los métodos *A1*, *A2*, *A3* y *A4* detectan correctamente tanto los bordes umbra-carretera no sombreada como bordes umbra-penumbra, sin embargo, la efectividad en la detección de bordes penumbra-carretera no sombreada es considerablemente menor. Los métodos *A1* y *A3* incluyen la condición de la Eq. (33), y el método *A2* incluye la condición de la Eq. (30), las cuales no son satisfechas por los




Figura 4.8. Mapas de bordes resultantes tras aplicar los cinco métodos. (a) *A1* método, (b) *A2* método, (c) *A3* método, (d) *A4* método y (e) el método método.

Table 4.2. Análisis cuantitativo

Método	SDR (%)	SDA (%)
<i>A1</i>	83.7	74.1
<i>A2</i>	82.4	65.8
<i>A3</i>	86.6	75.2
<i>A4</i>	84.1	69.8
<i>Algoritmo propuesto</i>	96.3	93.7

bordes separando penumbra-carretera no sombreada como se muestra en la sección 4.4.3. El método *A4* no es robusto detectando bordes difusos de la sombras (penumbras) como es comentado en [90].

En cuanto a la identificación de los bordes debidos a un cambio de material, la efectividad del método propuesto puede ser observada en la correcta detección de los bordes causados por los vehículos, líneas de carril, etc. el comportamiento es muy robusto ya que detecta satisfactoriamente los bordes debidos a un cambio de material en regiones de la escena sombreadas (izquierda de la escena) y en regines no sombreadas (derecha de la escena).

Las detecciones de bordes debidos a un cambio de material proporcionadas por *A1* y *A3* son bastante robustas mientras que la efectividad del método *A2* es baja. Esto se debe a que el método *A2* se basa únicamente en dos condiciones (componente azul normalizada e intensidad), las cuales son generalmente satisfechas por objetos neutros en la sombra y por los objetos azulados en regiones no sombreadas con una intensidad menor que el umbral obtenido de la carretera. Se ha de decir, que el método *A2* está diseñado para centrarse únicamente en la carretera donde su efectividad es más alta. Del mismo modo, la detección de los bordes de material del método *A4* es baja. *A4*

tiende a clasificar erróneamente los bordes que delimitan cambios de material que difieren únicamente en intensidad como bordes de sombras, debido a que no se encuentran bordes en la imagen invariante con la iluminación. Este hecho puede ser apreciado en la Fig. 4.9(d) con los bordes que limitan las líneas de carríl y el asfalto. Hemos de decir que tanto el método *A3* como el *A4* no se centran en detectar los bordes de sombras, sino en la segmentación total de las mismas, las cuales están mayoritariamente formadas por umbra donde la tasa de detección de ambos métodos es considerablemente alta.

Los resultados muestran la alta efectividad y fiabilidad del método propuesto identificando tanto bordes de sombra como bordes debidos a cambios de material.

4.7 Conclusiones

Este capítulo presenta un nuevo método para detectar los bordes de las sombras en la carretera basado las propiedades físicas de las mismas. Se describe la iluminación en exteriores en condiciones soleadas, la cual está formada por dos tipos de luz con distinta distribución espectral (luz del sol y luz del cielo) y se proponen tres nuevas observaciones en base a la contribución de la luz del sol en la cromaticidad de la superficie. También se describe la variación cromática no lineal de las penumbras.

El método propuesto aborda por separado la detección de los bordes causados por las umbras y los causados por las penumbras.

Ensayos llevados a cabo en complicadas escenas de tráfico urbano demuestran la fiabilidad y efectividad del método propuesto, clasificando bordes de sombra y bordes debidos a un cambio de material. Además, el

método propuesto demuestra cuantitativamente y visualmente, mejor comportamiento que cuatro métodos del estado del arte, alcanzando una tasa de detección de bordes de sombra *SDR* del 96.3% y una precisión de la detección *SDA* del 93.7%. Sin embargo, se pueden producir posibles errores en la clasificación de bordes debidos a un cambio de material (líneas amarillas pintadas en el asfalto), las cuales pueden satisfacer en algunos casos las condiciones de los bordes de sombra.

Capítulo 5

CONCLUSIONES Y TRABAJO FUTURO

En este último capítulo se recogen las conclusiones extraídas de las investigaciones llevadas a cabo durante la elaboración de la Tesis y se sugieren diversos trabajos futuros que complementarían el realizado a lo largo de la misma. Adicionalmente, se detallan las principales aportaciones originales derivadas de los métodos desarrollados.

5.1 Conclusiones

Detección de vehículos

Dentro del problema de la detección de vehículos basada en visión por computador, el objetivo planteado era el desarrollo de un sistema capaz de detectar la presencia de un vehículo precedente en la trayectoria. El sistema estaba además ideado para tráfico urbano donde uno de los tipos de accidente más frecuentes son las colisiones entre vehículos.

Son diversos los factores encontrados que han dificultado en gran medida la detección de vehículos en la imagen. En primer lugar, la detección no se puede reducir a la búsqueda de un vehículo con unas características únicas, habiendo sido necesario el desarrollo de un método basado en características de la apariencia comunes a todos los vehículos.

Por otro lado, al estar el ego-vehículo en constante movimiento, el escenario de la carretera es desconocido y cambiante en cada imagen, lo cual no permiten tener conocimiento a priori de la escena. Además, los entornos urbanos presentan fondos de imagen repletos de objetos interfiriendo con el vehículo. Esto unido a los problemas que causa la iluminación cambiante propia de los entornos exteriores, hace que nos encontremos con uno de los escenarios más desfavorables en los que puede operar un sistema basado en visión por computador.

El método que se ha desarrollado afronta inicialmente todas estas dificultades no por medio de la búsqueda del vehículo en sí, sino por la búsqueda de su sombra proyectada en la carretera. Se ha propuesto una estrategia nueva para la detección de la misma que es una alternativa a los métodos existentes en el estado del arte.

El método se centra en distinguir entre las transiciones de intensidad de la imagen originadas por la sombra y las originadas por otros elementos de la escena. Este proceso se lleva a cabo mediante la comparación de las propiedades cromáticas de los píxeles a ambos lados de las transiciones. A partir de las transiciones resultantes se establece un umbral de intensidad. De este modo, las regiones con menor intensidad que el umbral son candidatas a ser la sombra bajo un vehículo. Con el fin de descartar posibles sombras adyacentes, se vuelve a aplicar el umbral de intensidad individualmente a cada candidato. Finalmente, tras un filtrado morfológico

en base al conocimiento previo de las traseras de los vehículos, se establece una región de interés ROI la cual abarca el área de la carretera enfrente del ego-vehículo. Únicamente los candidatos a sombra localizados dentro de la ROI son considerados hipótesis generadas definitivas.

La estrategia de verificación de hipótesis desarrollada, está basada en la evaluación de características de la apariencia comunes a todas las traseras de los vehículos. Los candidatos a vehículo son verificados usando una combinación de tres características: bordes horizontales, verticales y simetría de la trasera del vehículo.

Los ensayos llevados a cabo en tráfico urbano real bajo diferentes condiciones ambientales, demostraron una gran robustez y efectividad del método propuesto para la detección del vehículo precedente en la trayectoria. El método de generación de hipótesis proporcionó unas altas tasas en la detección de positivos, alcanzando el 98.04% y 97.64% en condiciones nubladas y soleadas respectivamente. Además, demostró un mejor comportamiento en la etapa de umbralizado que el bien conocido método propuesto en [47]. El error más frecuente que se produce en la generación de hipótesis no se debe principalmente a vehículos no detectados sino a vehículos incorrectamente enmarcados.

En cuanto a la verificación de hipótesis, los ensayos mostraron una tasa de detección de positivos del 99.5%, la cual depende fuertemente del correcto enmarcado de la trasera de los vehículos. Las hipótesis correspondientes a vehículos incorrectamente enmarcadas fallan generalmente con la condición de bordes verticales.

Los resultados del sistema completo mostraron un efectivo y muy fiable comportamiento, alcanzando una tasa de detección del 97.4%. Un hecho significativo es que el método desarrollado opera correctamente para las

diversas condiciones de iluminación de la escena, para todo tipo de asfalto e independientemente de la distancia existente entre el vehículo precedente y el ego-vehículo.

En cuanto al coste computacional, el tiempo medio de procesado alcanzado es de 248.4768 ms, el cual supone el análisis de 4 imágenes por segundo (4 fps). El sistema ha sido desarrollado y probado mediante un ordenador portátil convencional con las limitaciones que esto supone, pero se espera que alcance un mayor número de imágenes analizadas por segundo mediante una unidad de procesado preparada al efecto.

Cálculo de la distancia

Dentro del problema del cálculo de la distancia, el objetivo era desarrollar un método capaz de estimar la distancia del vehículo precedente circulando en la trayectoria. Los sistemas basados en monovisión no son capaces de proporcionar de una manera precisa la distancia a la que circula el vehículo precedente, delegando esta imprescindible tarea en sistemas basados en estereovisión o en otras tecnologías como radar o LIDAR.

El sistema desarrollado aborda la estimación de la distancia mediante la relación existente entre la posición vertical del borde inferior del marco que contiene al vehículo detectado (borde superior del gradiente de la sombra bajo el mismo) y la distancia a la que éste se encuentra. Sin embargo, debido a la resolución de la imagen adoptada, el rango de medida fiable no supera los 8m de distancia. Si el vehículo circula a más de 8m, el sistema proporciona una medida de distancia superior a los 8m, pero ésta no será fiable.

El funcionamiento del método no pudo ser testado en movimiento debido a

la dificultad de encontrar un método o instrumento que proporcionara bajo estas condiciones una medida fiable que validara la medida de distancia proporcionada por el método propuesto.

Detección de bordes de sombra en la carretera

En la segunda parte de esta Tesis Doctoral se abordó el problema de la detección de bordes de sombra en la carretera. El objetivo planteado era una vez calculado el mapa de bordes de la imagen, identificar y eliminar los bordes originados por los límites de las sombras. Para así conseguir un mapa de bordes formado únicamente por los bordes generados por los objetos de la escena.

Habiendo encontrado los escenarios desfavorables propios del entorno urbano y de iluminación ambiental, es decir, escenario de la carretera desconocido, cambiante y con una iluminación impredecible, se ha desarrollado un método para la detección de los bordes de las sombras proyectadas en la carretera basado en las propiedades físicas, tanto de la iluminación como de la superficie.

El método propuesto no requiere calibración de la cámara y considera dos fuentes de iluminación con distintas distribuciones espectrales: la luz del sol y la luz del cielo, centrándose en distinguir entre los bordes de las sombras y los bordes causados por un cambio de material mediante la comparación de píxeles a ambos lados de los bordes de la imagen. Para ello, se abordaron separadamente las umbras y las penumbras mediante la observación de sus diferentes propiedades espectrales. Para las umbras, se explotaron algunas observaciones acerca de la cromaticidad de las sombras, y se presentaron tres nuevas restricciones en base a la contribución de la luz del sol en la

cromaticidad de la superficie. Además, se describió la variación no lineal de la cromaticidad en la penumbra y se planteó un método para clasificar bordes delimitando umbras, penumbras y regiones de la carretera no sombreadas.

Los ensayos llevados a cabo en escenas de tráfico urbano demuestran la fiabilidad y efectividad del método propuesto, clasificando bordes de sombra y bordes debidos a un cambio de material.

El método propuesto demostró cuantitativamente y visualmente, mejor comportamiento que cuatro métodos del estado del arte, alcanzando una tasa de detección de bordes de sombra *SDR* del 96.3% y una precisión de la detección *SDA* del 93.7%. Sin embargo, se observó que se pueden producir posibles errores en la clasificación de bordes debidos a las líneas amarillas pintadas en el asfalto, las cuales satisfacen en algunos casos las condiciones de los bordes de sombra.

5.2 Contribuciones

Se considera que este trabajo de Tesis Doctoral aporta las siguientes contribuciones a la detección de vehículos y a la detección de sombras:

- Se ha propuesto un nuevo método para la fase de generación de hipótesis de vehículo basado en la sombra proyectada bajo los mismos. Al contrario que aquellos métodos que detectan la sombra mediante un umbral de intensidad que consiste en un límite inferior de la intensidad de la carretera, el umbral propuesto en esta Tesis consiste en un límite superior de la sombra bajo el vehículo. Reduciendo considerablemente el número de falsas detecciones.
- Se ha propuesto un método para estimar la distancia del vehículo

precedente mediante la sombra bajo el vehículo y mediante un proceso de calibrado previo del sistema.

- Se ha propuesto un método para la identificación de los bordes de sombra en la carretera. Se incluyen tres nuevas restricciones basadas en la observación de la variación de las propiedades cromáticas de la superficie en función de la iluminación.

5.3 Trabajo Futuro

El presente trabajo de tesis se encuentra en una fase relativamente temprana, quedando aún mucho trabajo por realizar. Entre las tareas a desarrollar están las siguientes:

Respecto a los métodos desarrollados:

- Se pretende realizar una mejora en el enmarcado de las hipótesis generadas, con el fin de proporcionar un mayor número de hipótesis conteniendo vehículos correctamente encuadrados. Mejorando así la tasa de detección de positivos.
- Se pretende desarrollar un método para el cálculo de la distancia del vehículo precedente que mejore el rango de distancias del sistema propuesto, así como el desarrollo de un sistema mediante otras tecnologías capaz de llevar a cabo la validación en movimiento.
- Se pretende estudiar más profundamente el comportamiento de la cromaticidad ante los diversos tipos de iluminación (sol, cielo) tanto de las líneas amarillas de carril como del asfalto, con el fin de desarrollar

nuevas restricciones cromáticas que permitan una mejor clasificación de los bordes causados en la imagen por las transiciones asfalto-línea amarilla.

- Se pretende desarrollar un sistema para la detección de sombras y segmentación de la carretera que será la continuación más inmediata del sistema propuesto en esta Tesis para la detección de los bordes de sombra en la carretera.

Respecto a la línea de investigación entorno a los sistemas de ayuda a la conducción ADAS basados en visión:

- Se pretende desarrollar un sistema de detección de las líneas de carril para entrar a formar parte de un Sistema de Aviso de Salida de Carril (LDW). La fase inicial de este sistema será el método de detección de bordes de sombra propuesto en la presente Tesis.
- Se pretende desarrollar un sistema de detección de peatones en la carretera para entrar a formar parte de un Sistema de Detección de Peatones con Frenada de Emergencia (AEBS).

Referencias

1. World Health Organization, WHO: Global status report on road safety 2009. URL:http://www.who.int/violence_injury_prevention/road_safety_status/2009
2. WHO: Decade of action for road safety 2011-2020: Global Launch. URL http://www.who.int/roadsafety/publication/decade_launch
3. G. Toulminet, M. Bertozzi, S. Mousset, A. Bemsrhair, A. Broggi: 'Vehicle Detection by Means of Stereo Vision-Based Obstacles Features Extraction and Monocular Pattern Analysis', IEEE Trans. Intell. Trans. Systems, August. 2006, vol. 15, no. 8, pp. 2364-2375.
4. Z. Sun, G. Bebis, R. Miller, On-road vehicle detection: a review, IEEE Trans. on Pattern Anal. and Mach. Intell. 28 (2006) 694-711.
5. M. Bertozzi, A. Broggi, S. Castelluccio, A real-time oriented system for vehicle detection, J. Syst. Architecture, (1997) 317-325.
6. D. Guo, T. Fraichard, M. Xie, C. Laugier, Color modelling by spherical influence field in sensing driving environment, in: Proc. of IEEE Intell. Veh. Symp. Dearborn, 2000, pp. 249-254.
7. A. Kuehnle, Symmetry-based recognition for vehicle rears, Pattern Recognition Letters, 12 (1991) 249-258.
8. M.B. Van Leeuwen, F.C.A. Groen, Vehicle Detection with a Mobile Camera, Spotting Midrange, Distant and Passing Cars, IEEE Robotics and Automation Magazine, 12 (2005) 37-43.
9. M. Cheon, W. Lee, C. Yoon, M. Park, Vision-Based Vehicle Detection System with Consideration of the Detecting location, IEEE Trans. Intell. Trans. Syst. 13 (2012) 1243-1252.
10. S.S. Teoh, T. Braunl, Symmetry-based Monocular Vehicle Detection System, Mach. Vision and Applications, 23 (2012) 831-842.
11. T. Zielke, M. Brauckmann, W. V. Seelen, Intensity and edge-based symmetry detection with an application to car-following, CVGIP: Image Understanding, 58(2) (1993) 177-190.
12. L. Wei, W. XueZhi, D. Bobo, Y. Huai, W. Nan, Rear Vehicle Detection and Tracking for Lane Change Assist, IEEE Intelligent Vehicles Symposium, 2007, pp. 252-257.
13. N. Matthews, P. An, D. Charnley, C. Harris, Vehicle Detection and Recognition in Greyscale Imagery, Control Eng. Practice, (4)(1996), 473-479.

14. N. Srinivasa, A vision-based vehicle detection and tracking method for forward collision warning, In: Procc. IEEE Intelligent Vehicle Symposium, pp. 626-631, 2002.
15. J. Li-sheng, G. Bai-yuan, W. Rong-ben, G. lie, Z. Yi-bing, L. Lin-hui, Preceding Vehicle Detection Based on Multi-characteristics Fusion, in: IEEE International Conference on Vehicular Electronics and Safety, 2006, pp. 356–360.
16. M. Betke, E. Haritaoglu, L.S. Davis, Real-time multiple vehicle detection and tracking from a moving vehicle, Machine Vision and Applications, 12(2)(2000) 69–83.
17. J. Liu, Y.Z. Yua, W. Luo, K. Liu, Vehicle capturing and counting using a new edge extraction approach, in: Procc IEEE Int. Conf. on Intelligent Transportation Sys. 2011, pp. 62-66.
18. G. Y. Song, K. Y. Lee, J.W. Lee, Vehicle detection by edge-based candidate generation and appearance-based classification, in: Proc: IEEE intelligent Vehicle symposium, 2008, pp. 428-433
19. T. Wang, N. Zheng, J. Xin, Z. Ma, Integrating millimeter wave radar with a monocular vision sensor for on road obstacle detection applications, Sensors 11(9)(2011), 8992-9008.
20. J. Lan, M. Zhang, A new vehicle detection algorithm for real-time image processing system, in: Int. Conf. on Computer Application and System Modeling (ICCASM), 2010, pp. 10-14.
21. T. Kalinke, C. Tzomakas, W. von Seelen, A texture-based object detection and an adaptative model-based classification, in:Proc. of IEEE International Conference on Intelligent Vehicles, Sttutgard, 1998, pp143-148.
22. C. Rotaru, T. Graf, J. Zhang, Color image segmentation in HIS space for automotive applications, Journal of Real Time Image Processing, 3(4) (2008) 311-322.
23. L. W. Tsai, J. W. Hsieh, K. C. Fan, Vehicle detection using normalized color and edge map, IEEE Transactions on Image Processing, 16(3) (2008) 850-864.
24. R. Cucchiara, M. Piccardi, Vehicle Detection under Day and Night Illumination, in:Proc. Int'l ICSC Symp. Intelligent Industrial Automation, 1999.
25. T. Schamm, C. Carlowitz, J. Zollner, On-road vehicle detection during dusk and at night, in:Proc. IEEE Intelligent vehicle Symposium, 2010, pp 418-423
26. Y. L. Chen, Y. H. Chen, C. J. Chen, Night time vehicle detection for driver assistance and autonomous vehicles, in Proc: International conference on Pattern Recognition, (2006) pp 687-690.

27. J. M. Mossi, A. Albiol, An. Albiol, V. N. Ornedo, Real-time traffic analysis at night-time, in: Proc. International Conference on Image Processing, 2011, pp. 4941-2944.
28. L. Gao, C. Li, T. Fang, Z. Xiong, Vehicle detection based on color and edge information, in: Proc. in Image Analysis and Recognition, Lectures Notes in Computer science, (5115)(2008)142-150.
29. S. Kubota, T. Nakano, Y. Okamoto, A global optimization algorithm for real-time stereo obstacle detection systems, In: Proc: IEEE Intelligent Vehicle Symposium, 2008, pp. 7-12.
30. N. Chumering, M.M. Van Hulle, Cue and sensor fusion for independent moving objects detection and description in driving scenes, Signal Processing Techniques for Knowledge Extraction and Information Fusion. (2008) 161-180.
31. N. Simond, Reconstruction of the road plane with an embedded in stereo-rig urban enviroment, In: Proc. Intelligent Vehicle Symposium, 2006, pp. 70-75.
32. H. A. Mallot, H. H. Bulthoff, J. J. Little, S. Bohrer, Inverse perspective mapping simplifies optical flow computation and obstacle detection, Biological Cybernetics 64(3),(1991), 177-185.
33. G. Zhao, S. Yuta, Obstacle detection by vision system for autonomous vehicle, in: Proc. Intelligent Vehicle Symposium, 1993, pp. 31-36.
34. M. Bertozzi, A. Broggi, GOLD: A Parallel Real-Time Stereo Vision System for Generic Obstacle and Lane Detection, IEEE Trans. Image Process. 7 (1998) 62-81.
35. C. Knoepfel, A. Schanz, B. Michaelis, Robust Vehicle Detection at Large Distance Using Low Resolution Cameras, in: Proc. IEEE Intelligent Vehicle Symp., 2000, pp. 267-272.
36. S. Nedevschi, R. Danescu, T. Marita, et al, A Sensor for Urban Driving Assistance Systems Based on Dense Stereovision, in: IEEE Intell. Vehicles Symp. Istambul, 2007, pp-276-283.
37. S. M. Smith, J. M. Brady, ASSET-2: real-time motion segmentation and shape tracking, IEEE Trans. on Pattern Analysis and Machine Intelligence, 17(8)(1995), 814-820.
38. B. Heisele, W. Ritter, Obstacle detection based on color blob flow, in: Proc. of the Intelligent Vehicles '95 Symposium, 1995, pp. 282-286.
39. T. Naito, T. Ito, Y. Kaneda, The obstacle detection method using optical flow estimation at the edge image, In: Proc. Intelligent Vehicles Symposium, 2007, pp. 817-822.
40. F. Woelk, R. Koch, Robust monocular detection of independent motion by moving observer, in:Proc. Int. Conf. on Complex Motion, 2004, pp. 2009-2016.

41. C. Yanpeng, A. Renfrew, P. Cook, Vehicle motion analysis based on a monocular vision system, in: ITS United Kingdom Members' Conference, 2008, pp. 1–6.
42. D. Willersinn, W. Enkelmann, Robust obstacle detection and tracking by motion analysis, in: IEEE Conference on Intelligent Transportation System, (1997), pp. 717–722.
43. H. Mori, N. Charkai, Shadow, Rhythm as Sign patterns of Obstacle Detection, in: Proc. Int. Symp. Ind. Electronics, Budapest, 1993, pp. 271–277.
44. F. Thomanek, E. D. Dickmanns, D. Dickmanns, Multiple object recognition and scene interpretation for autonomous road vehicle guidance, in: Proc. of Intell. Vehicles'94 Symp. 1994, pp. 231–236.
45. S. Raboisson, P. Schmouker, Obstacle Detection in Highway Environment by Colour ccd Camera and Image Processing Prototype Installed in a Vehicle, Intell. Vehs, (1994) 44–49.
46. U. Handman, T. Kalinke, C. Tzomakas, M. Werner, W.v. Seelen, An Image Processing System for Driver Assistance, Image and Vision Computing, (2000) 367–376.
47. C. Tzomakas, W. Seelen, Vehicle Detection in Traffic Scenes using Shadows, Tech. Rep. 98-06, Institut FurNeuroinformatik, Ruht-universitat, Bochum, Germany, 1998.
48. J. M. Rubin, W. A. Richards, Color vision and image intensities: when are changes material?, Biol. Cybern. 45 (1982) 215–226.
49. E. Salvador, A. Cavallaro, T. Ebrahimi, Cast shadow segmentation causing invariant color features, Computer Vision and Image Understanding, 95(2) (2004) 238–259.
50. A. Hanbury, A 3D-polar coordinate colour representation well adapted to image analysis, in: Proc. 13th Scandinavian Conference on Image Analysis, 2003, pp. 804–811.
51. J. Kender, Saturation, Hue, Normalized Color: Calculation, Digitization Effects, and Use, Tech. Rep. Carnegie-Mellon University, 1976.
52. Y. Otha, T. Kanade, T. Sakai, Color Information for Region Segmentation, Comput. Graph. Image Process. 13(1980), 222–241.
53. G. Healey, Segmenting Images Using Normalized Color, IEEE Trans. Syst. Man and Cybernetics, 22 (1992) 64–73.
54. M. A. Sotelo, F. J. Rodriguez, L. Magdalena, et al, A Color Vision-Based Lane Tracking System for Autonomous Driving on Unmarked Roads, Autonomous Robots, 16 (2004) 95–116.
55. N. Ikonomakis, K. N. Plataniotis, A. N. Venersanopoulos, Color Image Segmentation for Multimedia Applications, J. Intell. Robot. Syst. (2000) 5–20.

56. S. Sural, G. Quin, S. Pramanic, Segmentation and Histogram Generation Using the HSV Color Space for Image Retrieval, in: IEEE Int. Conf. on Image Processing, 2002, pp. 589–592.
57. A. Shafer, Using color to separate reflection components, *Color Res. Appl.* 10 (1985) 210–218.
58. R. Gershon, A.D. Jepson, J.K. Tsotsos, Ambient illumination and the determination of material changes, *J. Opt. Soc. Am. A*, 3(10) (1986) 1700–1707.
59. P. Parodi, G. Piccioli, A Feature-Based Recognition Scheme for Traffic Scenes, in: Proc. IEEE Intelligent Vehicles Symp., 1995, pp. 229-234.
60. A. Benschraoui, M. Bertozzi, A. Broggi, P. Miche, S. Mousset, G. Moulminet, A Cooperative Approach to Vision-Based Vehicle Detection, *IEEE Intelligent Transportation Systems*, (2001) pp. 209-214.
61. J. Wu, X. Zhang, A PCA Classifier and Its Application in Vehicle Detection, in: Proc. IEEE Int'l Joint Conf. Neural Networks, 2001.
62. D. Noli, M. Werner, W. von Seelen, Real-Time Vehicle Tracking and Classification, *Intelligent Vehicles*, (1995) 101-106.
63. M. Weber, M. Welling, P. Perona, Unsupervised Learning of Models for Recognition, in: Proc. European Conf. Computer Vision, 2000, pp. 18-32.
64. Z. Sun, G. Bebis, R. Miller, On-Road Vehicle Detection Using Gabor Filters and Support Vector Machines, in: Proc. IEEE Int. Conf. Digital Signal Processing, July, 2002.
65. W. Pratt, *Digital Image Processing*, Wiley, New York, 1991.
66. V. Petrovic, T. Cootes, Analysis of features for rigid structure vehicle type recognition, in: Proc. of British Machine Vision Conference, 2004, pp. 587-596B.
67. B. Leibe, K. Schindler, et al, Couple Object Detection and Tracking from Static Cameras and Moving Vehicles, *IEEE Trans. on Pattern Analysis and Machine Intell.*, 30(10)(2008), 1683-1698.
68. J. Michels, A. Saxena, A.Y. Ng, High Speed Obstacle Avoidance using Monocular Vision and Reinforcement Learning, in: 22nd Int. Conf. on Machine Learning, Bonn, Germany, 2005, pp. 593-600.
69. I. Gat, M. Benady, A. Shashua: A Monocular Vision Advance Warning System for the Automotive Aftermarket, SAE Technical Paper, 2005.
70. M. Nieto, J. Arróspeide, D. Stavens, L. Salgado, Road environment modelling using robust perspective analysis and recursive Bayesian segmentation, *Machine Vision and Appl.*, 22, (2011), 927-945.

71. S. Álvarez, M. Á. Sotelo, M. Ocaña, D. F. Llorca, I. Parra, L. M. Bergasa, Perception advances in outdoor vehicle detection for automatic cruise control, *Robotica*, 28 (2001), 765-779.
72. A. Prati, I. Mikic, M. Trivedi, Detecting Moving Shadows: Algorithms and Evaluation, *IEEE Trans. on Pattern Anal. and Mach. Intell.* 25(7) (2003), 918-923.
73. E. Salvador, A. Cavallaro, T. Ebrahimi, Cast shadow segmentation using invariant color features, *Computer Vision and Image Understanding*, 95 (2) (2004), 238-259.
74. A. Yoneyama, C.H. Yeh, C.-C.J. Kuo, Moving cast shadow elimination for robust vehicle extraction based on 2d joint vehicle/shadow models, in: *Proc. IEEE Conf. on Advanced Video and Signal Based Surveillance* (2003), pp. 229-236.
75. N. Martel-Brisson, A. Zaccarin, Learning and removing cast shadows through a multidistribution approach, *IEEE Trans. on Pattern Anal. and Mach. Intell.* 29(7) (2007), 1133-1146.
76. K. Irie, A. McKinnon, K. Unsworth, I. Woodhead, Noise-bound method for detecting shadow-free scene changes in image sequences, *J. Opt. Soc. Am. A* 27(2) (2010), 167-173.
77. J.V. Panicker, M. Wilscy, Detection of moving cast shadows using edge information, in: *The 2nd Int. Conf. on Computer and Automation Engineering (ICCAE)*, 2010, pp. 817-821.
78. A. Leone, C. Distanto, Shadow detection for moving objects based on texture analysis, *Pattern Recognition* 40(4) (2007), 1222-1233.
79. R. Cucchiara, C. Grana, M. Piccardi, A. Prati, Detecting moving objects, ghosts, and shadows in video streams, *IEEE Trans. on Pattern Anal. and Mach. Intell.* 25 (10) (2003), 1337-1342.
80. J. M. Alvarez, A. M. Lopez, Road Detection Based on Illuminant Invariance, *Trans. on Intell. Transp. Sys.* 12(1) (2011), 184-193.
81. J. B. Huang, C. S. Chen, Moving cast shadow detection using physics-based features, in: *IEEE Conference on Computer Vision and Pattern Recognition*, 2009, pp. 2310-2317.
82. J. M. Rubin, W. A. Richards, Color vision and image intensities: when are changes material?, *Biol. Cybern.* 45 (1982), 215-226.
83. R. Wallace, K. Matsuzaki, Y. Goto, J. Crisman, J. Webb, T. Kanade, Progress in Robot Road-Following, in: *Proceedings of IEEE Conference on Robotics Automation*, 1986, pp. 1615-1621.
84. I. Mikic, P.C. Cosman, G.T. Kogut, M.M. Trivedi, Moving shadow and object detection in traffic scenes, in: *Proc. IEEE Int. Conf. on Pattern Recognition (ICPR)*, 2000, pp. 321-324.

85. S. Nadimi, B. Bhanu, Physical models for moving shadow and object detection in video, *IEEE Trans. on Pattern Anal. and Mach. Intell.* 26(8) (2004), 1079–1087.
86. J. Klinker, S. A. Shafer, T. Kanade, Color Image Analysis with an Intrinsic Reflection Model, in: *The 2nd Int. Conf. on Computer Vision*, 1988, pp-292-296.
87. Y. Sato, K. Ikeuchi, Reflectance analysis under solar illumination, in: *Proc. of the Workshop on Physics-Based Modeling in Computer Vision*, 1995, pp-180-187.
88. J.A. Marchant, C.M. Onyango, Shadow Invariant Classification for Scenes Illuminated by Daylight, *J. Opt. Soc. Am., A* 17(12) (2000), 1952-1961.
89. J. K. Barnard, G. Finlayson, Shadow identification using colour ratios, in: *IS&T/SID 8th Color Imaging Conf.: Color Science, Science, Systems and Appl.* 2000, pp. 97–101.
90. G.D. Finlayson, S.D. Hordley, L. Cheng, M.S. Drew, On the Removal of Shadows From Images, *IEEE Trans. Pattern Anal. and Mach. Intell.* (28)1 (2006), 59-68.
91. G.D. Finlayson, S.D. Hordley, Color constancy at a pixel, *J. Opt. Soc. Am. A* 18 (2001), 253–264.
92. A. J. Joshi, N. P. Papanikolopoulos, Learning to detect moving shadows in dynamic environments, *IEEE Trans. Pattern Anal. and Mach. Intell.* 3(11) (2008), 2055-2063.
93. S. Park, S. Lim, Fast Shadow Detection for Urban Autonomous Driving Applications, in: *The IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2009, pp. 1717-1722.
94. H.-C. Lee, Method for Computing the Scene-Illuminant Chromaticity from Specular Highlights, *J. Opt. Soc. Am. A* 3(10) (1986), 1694-1699.
95. G.D. Finlayson, M.S. Drew, B.V. Funt, Spectral sharpening: sensor transformations for improved color constancy,” *J. Optical Soc. Am. A*, 11(5) (1994), 1553-1562.
96. A. Cavallaro, E. Salvador, T. Ebrahimi, Detecting Shadows in Image Sequences, in: *Proc. Of the European Conf. on Visual Media Production* (2004), pp. 167-174.
97. V. Risson, Application de la Morphologie Mathématique à l'Analyse des conditions d' Eclairage des Images Couleur, PhD thesis, Paris School of Mines, (2001).
98. J. Canny, A Computational Approach to Edge Detection, *IEEE Trans. on Pattern Anal. and Mach. Intell.* 8(6) (1986), 679-698.

99. J. M. Alvarez, T. Gevers, A. M. Lopez, 3D Scene Priors for Road Detection, in: Proc. of the IEEE conference on Computer vision and Pattern Recognition, 2010, pp. 57-64.

UNIVERSITY OF CANTABRIA

DEPARTMENT OF ELECTRONICS TECHNOLOGY,
SYSTEMS ENGINEERING AND AUTOMATION



PH.D THESIS

VISION-BASED VEHICLE
DETECTION AND LOCATION
USING SHADOWS

MANUEL IBARRA ARENADO
INDUSTRIAL ENGINEER

2016

Acknowledgement

I would like to express my sincere gratitude to:

- my thesis director Dr. Juan M. Pérez Oria for his invaluable support, motivation and guidance during this thesis.
- my mates of the Control Engineering Group for all their good advices and help given.
- the National Program for Training Research Staff (FPI) of the Spanish Ministry of Economy and Competitiveness.
- Dr. Tardi Tjahjadi for his invaluable help and for giving me the opportunity to work under his supervision at the School of Engineering of the University of Warwick, Coventry, United Kingdom.
- Ivo and Fran for they good friendship.
- Andrés, Azucena, Bárbara, Chisco, Cos, David, Gustavo, Juancar, Laura, Susana, Teresa y Zoraida because they are the best friends.
- my parents Manuel y Manuela, my sisters Ana and Isabel, and my niece Ana because they are what I most love in the world.

ABSTRACT

This thesis addresses three issues: 1) a vision-based system for on-road vehicle detection in urban traffic, 2) vehicle distance measurement and 3) shadow edge detection on the road.

On-road vehicle detection

Firstly, a monocular vision-based system to detect vehicles ahead in the target path is presented. The method consists of two stages: hypotheses generation (HG) and hypotheses verification (HV).

Hypotheses are generated according to the shadowed road region under the vehicles. We propose a new strategy for the detection of the shadow under a vehicle which overcomes significant difficulties such as the presence of lateral shadows and cluttered roads.

The method of detecting shadow under a vehicle proposed initially focuses on distinguishing the intensity transitions on the road due to shadow under the vehicle from those due to other elements by comparing pixel properties across them. From the set of upper pixels of the resulting transitions and based on the fact that the shadow under a vehicle is a very dark road region, a coarse intensity threshold is determined so that regions with intensity smaller than the threshold become candidates of the shadow. For each candidate, a refined intensity threshold is applied to reject adjacent transitions due to lateral shadows. Finally, after morphological filtering based on the knowledge of the pose and size of the vehicle, a ROI covering the frontal road area of the ego-vehicle is established. Only vehicles within the ROI are susceptible to a possible rear-end collision with the ego-vehicle,

therefore only candidates within the ROI are considered the final vehicle hypotheses.

The method proposed correctly works under different illumination and different types of asphalt. The method demonstrates high rates in positive hypotheses detection.

The hypotheses verification strategy is based on the evaluation of appearance features common to all vehicle rears. Hypotheses provided by the HG stage are verified using a combination of three vehicle features namely, vertical and horizontal edges, and symmetry. A vehicle candidate has to satisfy the three feature constraints to be finally verified as vehicle.

Distance measurement

After vehicle detection the gap distance between the vehicle ahead and the ego-vehicle is determined. The measurement of an object using one camera can be done in two ways: 1) by the knowledge the surface plane (road) of the image, and 2) from a frontal view and the knowledge of the true magnitude of the object. Both methods require system calibration.

The size of the vehicle depends on its make and model, however the shadow under the vehicle can be assumed as the vertical projection of the vehicle onto the road.

The vehicle distance measurement method proposed exploits the shadow under the vehicle and the flat road assumption. The measurement of the distance is in a straightforward manner from the relationship relating the vertical location of the shadow under the vehicle in the image (in pixels) and the distance to the ego-vehicle (the method requires an initial calibration procedure).

Shadow Edge Detection in Road Scenes

Finally, a physics-based method for shadow edge detection in road scenes is proposed. The method does not require camera calibration and considers two illumination sources with different SPDs: skylight and sunlight. In as much as ADAS deal with non-static background scenes, the proposed method focuses on distinguishing shadow boundaries from material changes by comparing pixel properties across image edges. The method addresses umbras and penumbras separately by exploiting their different spectral properties. For umbras, some existing shadow chrominance observations are exploited and three new constraints on the basis of sunlight contribution to the surface chromaticity are proposed. In addition, we discuss the non-linear chromaticity variation in penumbras and propose a method to classify edges delimiting umbras, penumbras and non-shadowed road regions.

CONCLUSIONS

On-road vehicle detection

The main aim was to develop a system to detect a vehicle ahead in the target path. It was intended to work in urban traffic, where most of the accidents are rear-end collisions.

Several factors which make difficult the vehicle detection have been found. First, the vehicle detection procedure cannot focus on a specific object so the method developed focuses on appearance features common to all vehicles.

Moreover, the vehicle is moving and thus the road scene is constantly changing, so there is no a priori scene information. In addition, urban roads are characterized by cluttered backgrounds which cause apparent merging of the scene elements and the vehicle in the image. This together with outdoors illumination contribute to make ADAS environment one of the most difficult scenario for a vision-based system.

The method developed overcomes most of the aforementioned difficulties by the search of the shadowed road region under the vehicle. A new strategy for the detection of the shadow under the vehicle has been proposed focusing on distinguishing the intensity transitions on the road due to shadow under the vehicle from those due to other elements by comparing pixel properties across them and intensity thresholding.

On the other hand, candidates provided by the hypotheses generation stage are verified using a combination of three vehicle features namely, vertical and horizontal edges, and symmetry.

Tests carried out in real urban traffic scenes under different weather demonstrate the robustness and the effectiveness of the proposed method in detecting vehicles ahead travelling in the target path. The hypotheses generation method gives high rates in positive detection, achieving 98.04% and 97.64% on cloudy and sunny days, respectively. Furthermore, the proposed method achieves better performance in the intensity thresholding than the well known method in [47]. The most frequent error in HG is not mainly due to vehicles missed but vehicles detected that are incorrectly framed. Regarding the hypotheses verification, tests showed a positive detection rate of 99.5% which strongly depends on the correct framing of vehicle rear. Hypotheses corresponding to vehicles incorrectly framed usually fail with the vertical edges constraint. Finally, the results of the complete

vehicle detection procedure show an effective and very reliable performance, achieving a vehicle detection rate of 97.4%.

The average processing time achieved was 248.4768 ms, which implies 4 fps. It is because of the limitations imposed by the processing unit employed, a common laptop. The algorithm is expected to be able to achieve a higher number of fps running on a suitable processing unit.

Distance measurement

The main aim was to develop a system to compute the gap distance between the vehicle ahead and the ego-vehicle. To date, the lack of works dealing with the issue of monovision-based vehicle distance estimation makes this task very challenging. Monovision does not provide depth information, so it is difficult to accurately determine the distance of the vehicle ahead.

The proposed method addresses the distance measurement by the relationship relating the vertical location of the shadow under the vehicle in the image and the distance to the ego-vehicle. The method requires an initial calibration procedure.

Owing to the low image resolution adopted, the distance range is up to 8m. Distance values provided by vehicles travelling further than 8m are not reliable. The accuracy and range would improve for higher image resolution although processing time would be longer.

The performance of the method was not able to be checked in motion owing to the difficulty of finding an instrument providing reliable measurements in motion.

Shadow Edge Detection in Road Scenes

The main aim was to develop a system to detect shadow edges cast on the road. We discuss the illumination in outdoor environments under sunny conditions, which comprises two light sources with different SPDs, i.e., skylight and sunlight, and their effect on the road surface. We also present the chrominance features of umbras and the non-linear chromaticity variation in penumbras. The proposed method addresses separately the detection of both umbras and penumbras, and this thesis introduces three new constraints for shadow edge detection on the basis of sunlight contribution to the surface chromaticity.

Tests carried out on complex road scenes acquired in real traffic demonstrate the robustness and the effectiveness of the proposed method in classifying shadow and material-change. Furthermore, the proposed method is shown to achieve better performance, visually and quantitatively, than four shadow detection methods achieving SDR of 96.3% and a SDA of 93.7%. However, there are possible misclassification of material-change edges due to yellow markings on the road, which in some cases (e.g., due to faded markings) may satisfy the shadow edge constraints.