

# eurofach

AÑO XVIII  
ENERO 94

270

Actualidad y  
Tecnología de la  
Industria Electrónica

# electronica

**Motorola Discretes**

**MOTOROLA**

**ARROW**

**THE COMPLETE SOLUTION**  
... Opto • RF • Sensors  
Power • Small-Signal

**Distribuidor oficial  
en  
España y Portugal**

**MOTOROLA**

Amplificadores de video logaritmicos con detector.

Protección contra EMI/RFI/ESD.

Guiado de robots móviles por carreteras mediante el uso de visión artificial.

Oportunidades para FDDI. Utilización en redes heterogéneas.

TekMeter, combinación de multímetro y osciloscopio. Innovaciones de diseño para los equipos de prueba multifunción.

Optoelectrónica.

Creación del programa Navsat. Funcionamiento, elementos constitutivos y aplicaciones.

Placa de visualización LCD para el bus STD.

Sistema racional GWS para el puesto de trabajo.

Nuevos Productos:  
Componentes, microelectrónica, instrumentación, máquinas, equipos, materiales, libros y catálogos.

# Guiado de robots móviles por carreteras

## Mediante el uso de visión artificial

Por Fco. Javier Rodriguez, Manuel Mazo, Jesús Urueña, M. Angel Sotelo. Departamento de Electrónica de la Universidad de Alcalá.

En este artículo se presenta una alternativa de guiado por carreteras de un robot móvil empleando visión artificial. El sistema desarrollado por los autores para detectar los bordes de la carretera, se basa en la extracción de características mediante estadísticos de primer y segundo orden (texturas), en una clasificación posterior en patrones (carretera, no-carretera) y en decidir la trayectoria mediante redes neuronales.

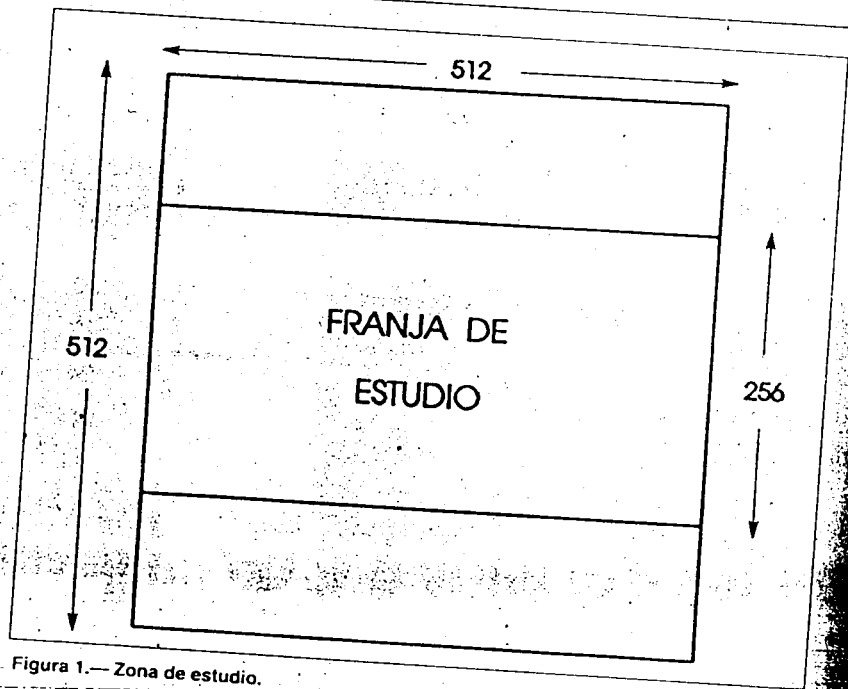


Figura 1.— Zona de estudio.

Los mayores obstáculos técnicos para la construcción de robots móviles autónomos, provienen de la visión y la navegación. Se trata, en resumen, de permitir a los robots conocer su entorno, planificar y seguir un camino seguro a través del medio en el que se encuentran y ejecutar las tareas que tenga programadas.

La visión artificial desempeña un papel clave tanto en el conocimiento del entorno como en el seguimiento de trayectorias.

Así, para hacer posible un auténtico robot móvil, debe ser dotado de elementos sensoriales diversos (infrarrojos, ultrasonidos, visión, etc) que le proporcionen información del entorno en el que se desen-

vuelve. Esta información deberá recibirla un nivel superior de control y planificación que decidirá en todo momento sobre las acciones a realizar.

Cuando el robot móvil se desenvuelva en espacios abiertos deberá hacer uso de las vías de desplazamiento establecidas de antemano, esto es, principalmente carreteras. Se plantea, pues, el problema del seguimiento de carreteras como una de las capacidades de las que ha de dotarse a un auténtico robot móvil autónomo.

En esta dirección apuntan numerosos trabajos de investigación, que intentan, mediante visión artificial, detectar las líneas marcadas en la carretera y en su defecto, los bordes

**L**os robots móviles desempeñan un importante papel en el mundo actual y es previsible que su importancia siga en aumento. Surgieron por los años 60 y hoy en día se ocupan de tareas difíciles para los humanos como la construcción de túneles, exploraciones en otros planetas, inspecciones submarinas, etc.

En la mayoría de las aplicaciones es deseable que el robot sea cuanto más autónomo mejor, para de esta forma reducir la intervención humana a niveles mínimos.

Fig

qu  
car  
de  
lla,  
pos  
a el  
may  
trad  
bien  
Es  
la in  
tera,  
dos  
dad,  
carre  
probl  
inclu  
encue  
segu  
ejemp  
horizc  
móvil  
encue  
viesa  
camb  
Algo  
seguim

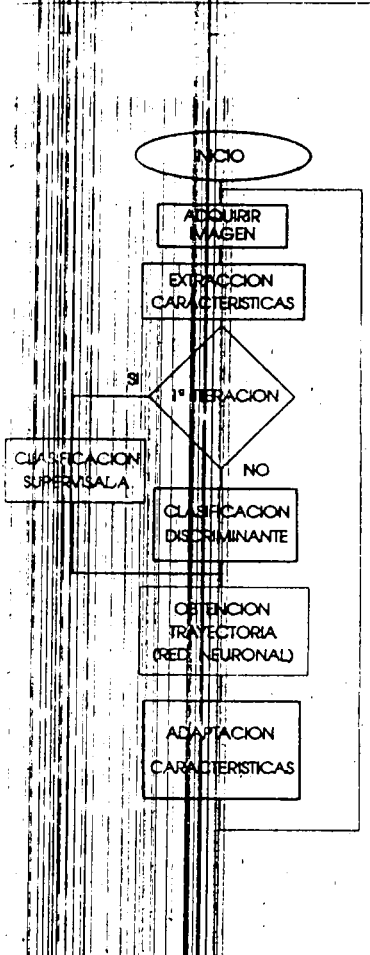


Figura 2.— Diagrama de flujo.

que aspiran la carretera de la no captada. Sin duda, el seguimiento de carreteras es un problema estrecho, a pesar por la cantidad de equipos de investigación que se dedican a ello. Sin entrar en detalles, en la mayoría de los casos se ha encontrado una solución parcial al problema.

Es posible guiar un móvil según la información extraída de la carretera cuando se cumplen determinados requisitos, tanto de luminosidad como de estado físico en la carretera. No son de extrañar estos problemas, si se tiene en cuenta que incluso los conductores humanos encuentran problemas a la hora de seguir una carretera cuando, por ejemplo, el sol se encuentra en el horizonte hacia el que se dirige el móvil, o cuando la carretera se encuentra en mal estado y se atravesa por zonas sombreadas o con algunos bruscos de luminosidad.

Algo similar ocurre en el caso del seguimiento automático, si bien de



Figura 3(a).— Imagen real.




Figura 3(b).— Aspecto después de ser filtrada.

forma más acusada. Por otro lado, como en el caso del conductor humano, es más fácil seguir una carretera perfectamente señalizada, con líneas en los bordes y en el centro, que aquellas otras sin señalización o con una señalización deficiente.

Se vislumbran, según lo comentado, dos estrategias de guiado del móvil. Una de ellas, consistente en seguir las líneas marcadas en la carretera, permite alcanzar velocidades relativamente altas, en el entorno de los 100 Km/h. La otra, consistente en detectar los bordes de la carretera por diferencias de textura o de color requiere un procesamiento más complejo y por ello permite menores velocidades.

También aquí se puede establecer la similitud con la conducción humana: si la carretera está perfectamente pintada la conducción es más fácil y se puede conducir a mayores velocidades que en el caso de carreteras mal pintadas o sin pintar, claro está, en igualdad de condiciones de asfalto.

Finalmente, el sistema que se pretenda robusto deberá incluir, al menos, ambas estrategias y decidir según el estado de la carretera que se siga.

### Estado del arte

Básicamente se plantean dos enfoques entre los distintos grupos de investigación. Los hay que pretenden conseguir un móvil capaz de seguir carreteras, sin que se tenga información previa alguna sobre las mismas. Son los proyectos más ambiciosos que, lógicamente, requieren grandes esfuerzos en visión artificial, en control, en desarrollo software y en la creación de

arquitecturas hardware de gran velocidad.

Otros grupos, considerando inviable y poco práctico el enfoque anterior, centran sus esfuerzos en llevar al móvil por redes de carreteras previamente conocidas. Este conocimiento, junto con la información obtenida de la carretera vía visión artificial, permite al móvil autónomo conseguir más fácilmente sus objetivos.

En Alemania Dickmanns y Grafe [1] enfocaron el problema del seguimiento de carreteras como un problema de control. Basándose en una simple detección de bordes de la carretera y en un modelo del vehículo, consiguieron conducirlo hasta 100 Km/h. Para acelerar el procesado centraron el estudio en una ventana. Sin embargo, el sistema falla cuando aparecen sombras o imperfecciones en la carretera.

En la Universidad de Maryland también se trata el tema [2], basándose en la extracción de bordes dentro de una ventana de estudio. Los bordes son agrupados empleando la transformada de Hough para determinar cuales forman el mejor borde de carretera. Al igual que en el caso anterior, el sistema falla cuando las carreteras no son muy buenas o cuando los bordes dominantes no son de carretera.

En la Universidad de Carnegie Mellon [3] se están desarrollando dos prototipos de vehículos autónomos capaces de moverse en espacios exteriores: el NAVLAB y el TERRAGATOR. Dentro del proyecto NAVLAB, la fase de seguimiento de carreteras está muy avanzada, basándose, esencialmente, en la toma de dos imágenes en color de la carretera con dos cámaras, una con el diafragma más abierto para detectar zonas oscuras y otra con el

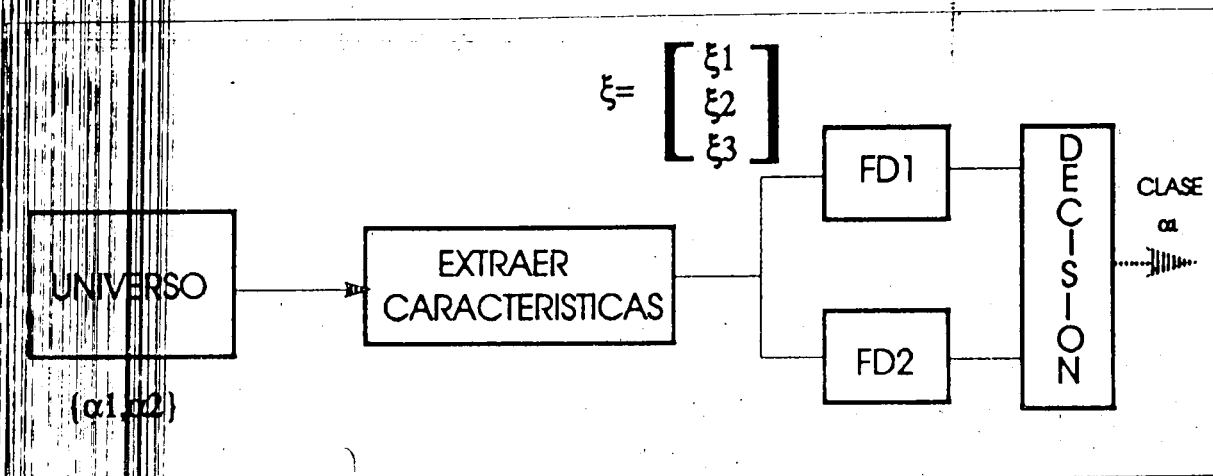


Figura 4.— Diagrama de bloques del proceso.

diafragma más cerrado para las zonas claras. Cada píxel es caracterizado por un vector (básicamente los niveles RGB de cada cámara) que sirve de entrada a un clasificador lineal que decide si el píxel pertenece a la carretera o no.

El sistema, que requiere de una arquitectura hardware desarrollada expresamente, funciona bien incluso en entornos muy sombreados o irregulares. Su principal inconveniente es la complejidad de las tareas software, y lo abundante del sistema hardware: la arquitectura antes comentada y varias workstations SUN y VAX.

En fase más primitiva se encuentran otros proyectos como el de la Universidad de Bristol [4]. El enfoque se basa en el conocimiento previo de la red de carreteras por las que se va a desenvolver el móvil autónomo.

Para el seguimiento de carreteras han decidido considerar varios modelos, pues difícilmente todos los casos se pueden resolver con un modelo único. Cuando el móvil se encuentra en tramos rectos emplean un modelo, y cuando está en tramos curvos, otro distinto.

Como base de los modelos han desarrollado módulos de bajo nivel que extraen la información de la carretera más adecuada en cada circunstancia: en caso de existir marcas, se centra en ellas el estudio, si no las hay, se recurre a otros métodos.

Por su parte, la Comunidad Europea financia un proyecto participada por los principales fabricantes de automóviles de Europa y por muchas instituciones de investigación.

El proyecto, denominado PROMETHEUS [5], trata sobre el impacto de la electrónica y los ordenadores en el transporte por autopistas. Incluye apoyo pasivo y activo al conductor, intercambio de señales entre vehículos, etc. El guiado automático del móvil por visión artificial es otro de los objetivos del programa, aunque no es un fin a corto ni medio plazo, pues se considera suficiente una conducción compartida, en la que el conductor humano mantenga parte de responsabilidad, siendo la conducción automática la predominante cuando las circunstancias sean adecuadas.

Asimismo en la Universidad de Alcalá de Henares se ha creado un grupo de trabajo para la integración en un robot móviles de varios módulos que le permitan moverse y conocer el entorno [6].

Ya se ha dotado al robot de un sistema que le permite seguir líneas pintadas en el suelo. También es capaz de detectar obstáculos en su camino y evitarlos. Actualmente se está desarrollando un módulo que le permite a través de la imagen captada por una cámara, seguir carreteras con o sin líneas. De los resultados obtenidos trata el resto del artículo.

### Seguimiento de carreteras

A la hora de decidir el método de seguimiento se debe tener presente, como ya se ha comentado, el estado de la carretera y su señalización. Si ésta es buena, los métodos basados en detección de líneas son los más adecuados, dado que permiten rapi-

dez de procesado y por ende velocidades de guiado rápidas. Cuando no es así, debe recurrirse a analizar las diferencias de texturas entre la carretera y los bordes.

Los métodos basados en el cálculo de estadísticos matemáticos son los más prometedores para caracterizar la textura de una carretera. El análisis adecuado de una imagen puede proporcionar el aspecto de cada una de las texturas que la componen, lo que puede resultar de gran importancia a la hora de discriminar las diferencias entre cada una de ellas.

Inicialmente, es conveniente estudiar el total de la imagen para calcular la distribución ubicacional de los elementos que la componen. Sin embargo, después de muchas pruebas prácticas se ha llegado a la conclusión de que restringiendo el análisis a zonas determinadas del estudio se pueden lograr excelentes resultados.

Por otro lado el hecho de recorrer la imagen completa para calcular varios estadísticos sobre ella implica un tiempo de cálculo elevado. En un sistema de seguimiento en tiempo real el período de muestreo debe reducirse al mínimo, con lo que resulta aconsejable practicar una política de simplificación de cálculos, siempre y cuando esto no repercuta en la robustez del sistema.

En nuestro caso se ha definido una franja de estudio de dimensiones 512 x 256 píxels. Tras efectuar varias pruebas prácticas sobre imágenes grabadas de tramos reales de carretera, resulta óptimo emplear la franja central de la imagen para el análisis de la misma. Esta recoge, de forma mayoritaria, la informa-

ción que proporciona la imagen y que resulta necesaria para la posterior extracción de características.

Por otro lado, esta zona de estudio no suministra zonas vastas correspondientes a la carretera, obteniéndose a través de la misma una visión global que permite realizar el seguimiento en condiciones óptimas. La Figura 1 muestra la ubicación de la misma.

Los pasos seguidos para generar una trayectoria a partir de la imagen tomada de la carretera se resumen en el organigrama de la Figura 2:

### Definición de estadísticos

Se definen en este apartado algunos de los estadísticos que se calculan sobre cada imagen. De los estadísticos de primer orden, se emplean la media aritmética del nivel de gris y la suavidad relativa y de los estadísticos de segundo orden, el contraste obtenido sobre la matriz de co-ocurrencia.

Los estadísticos de primer orden constituyen el procedimiento más sencillo para describir una textura. La definición de la media aritmética sobre una imagen o región dadas es la siguiente:

Sea  $z$  una variable aleatoria que representa la intensidad discreta de la imagen y sea  $p(z_i)$ , con  $i=1,2,\dots,L$  la función de densidad de probabilidad de la imagen correspondiente. Donde  $L$  es el número de niveles de intensidad distintos.

$$\mu(z) = \frac{H(z)}{N}$$

siendo  $N$  el número de puntos o pixels de la imagen y  $H(z_i)$  el número de pixels de nivel de gris  $z_i$ .

La media aritmética puede definirse como el valor medio de  $z$  (la intensidad media de la imagen o región) y su expresión es la que sigue a continuación:

$$\mu(z) = \sum_{i=1}^L z_i p(z_i)$$

A partir del cálculo del momento de segundo orden, llamado varianza y representado por  $\sigma^2(z)$  podemos definir el descriptor suavidad relativa  $R$  de la forma siguiente:

$$R = 1 - \frac{1}{1 + \sigma^2(z)}$$

el valor de  $R$  es 0 para áreas de intensidad constante y 1 para valores grandes de  $\sigma^2(z)$ , o sea, zonas con gran dispersión del nivel de gris.

Los estadísticos de segundo orden proporcionan un enfoque sencillo para medir las relaciones espaciales en un patrón de textura. Con este fin se emplean la Matriz de Co-ocurrencia de los niveles de gris  $C$  (GLCM). Para definirla partiremos de un ejemplo de imagen digitalizada en tres niveles de gris que es representada por la matriz  $I$ :

$$I(i,j) = \begin{pmatrix} 0 & 0 & 0 & 1 & 2 \\ 1 & 1 & 0 & 1 & 1 \\ 2 & 2 & 1 & 0 & 0 \\ 1 & 1 & 0 & 2 & 0 \\ 0 & 0 & 1 & 0 & 1 \end{pmatrix}$$

Recorriendo la matriz  $I$  según un operador de desplazamiento (que relaciona entre sí un nivel de gris de píxel con el situado una posición por debajo y a la derecha del mismo) se puede conseguir la matriz  $C$ :

$$C(i,j) = \begin{pmatrix} C_{11} & C_{12} & C_{13} \\ C_{21} & C_{22} & C_{23} \\ C_{31} & C_{32} & C_{33} \end{pmatrix} = \begin{pmatrix} 4 & 2 & 0 \\ 2 & 3 & 2 \\ 1 & 2 & 0 \end{pmatrix}$$

donde los subíndices representan los distintos niveles de gris (subíndice 1 al nivel de gris 0, subíndice 2 al nivel de gris 1 y subíndice 3 al nivel de gris 2). El elemento  $C_{11}$  representa el número de veces que el nivel de gris 0 (subíndice 1) aparece una posición por debajo y a la derecha del nivel de gris 0 (subíndice 1). El elemento  $C_{31}$  es el número de veces que el nivel de gris 2 (subíndice 3) aparece una posición por debajo y a la derecha del nivel de gris 0 (subíndice 1).

Una matriz de co-ocurrencia es una estimación de la distribución de los pares de niveles de gris separados espacialmente por un vector de desplazamiento especificado. Esta

matriz puede normalizarse como sigue:

Si se llama  $n$  al número total de pares de pixels de imagen que satisfacen al operador de posición (en el ejemplo que se trata  $n$  toma el valor 16, que sería la suma de los elementos de la matriz de co-ocurrencia), la Matriz de Probabilidad de Co-ocurrencia  $P$  se define como la obtenida tras dividir cada elemento  $c_{ij}$  de la matriz  $C$  por  $n$ .  $P_{ij}$  es, por tanto, una estimación de la probabilidad compuesta de que un par de puntos que se encuentren en la posición definida por el operador de desplazamiento empleado, tengan valores  $z_i, z_j$ .

Formalmente, siendo  $S$  el conjunto de todos los pares de pixels en una relación espacial dada, se define la matriz de probabilidad como:

$$p(m,n) = \sum_{(i,j), (k,l) \in S} I(i,j) = m \wedge I(k,l) = n$$

En el ejemplo anterior la matriz de probabilidad resulta:

$$p(i,j) = \begin{pmatrix} 4/16 & 2/16 & 0/16 \\ 2/16 & 3/16 & 2/16 \\ 1/16 & 2/16 & 0/16 \end{pmatrix}$$

Otro modo de plantear las matrices de co-ocurrencia de grises es considerar los pixels  $(i,j)$  como elementos de textura. El predicado restringido espacial vendrá dado como:

$$p(m,n) = \sum_{(i,j), (k,l) \in S} I(i,j) =$$

$$(4/16 \ 2/16 \ 0/16)$$

y que nosotros en lo que sigue definiremos como vector de desplazamiento  $d$ .

Se puede definir la GLCM  $h(i_m, i_n, d)$  con una restricción espacial dada por un vector de desplazamiento,  $d=(1,0)$  (dirección de  $0^\circ$ ). Si en su lugar empleásemos un desplazamiento  $-d$ , es decir,  $d=(-1,0)$ , y se calculase la GLCM correspondiente observaríamos que ésta es la matriz transpuesta de la anterior.

Por tanto se puede afirmar:




Figura 5 (a1)




Figura 5 (b1)




Figura 5 (c1)



Figura 5 (a2)




Figura 5 (b2)




Figura 5 (c2)

Figura 5. Ejemplos de segmentaciones obtenidas

$$p(m, n) = \sum_{(i,j), (k,l)} \delta S / I(i, j) =$$

siendo  $H^T$  la matriz transpuesta de

Se consigue una GLCM simétrica que no tiene en cuenta si el desplazamiento es  $d$  o  $-d$  de la forma:

$$p(m, n) = \sum_{(i,j), (k,l)} \delta S / I(i, j) = m \wedge I(k, l) = n$$

$$p(m, n) = \begin{pmatrix} 4/16 & 2/16 & 0/16 \\ 2/16 & 2/16 & 2/16 \\ 1/16 & 0 & 0/16 \end{pmatrix}$$

El contraste se define sobre los elementos de esta matriz simétrica. Considerando que  $I_m$  e  $I_n$  varían entre  $1, 2, \dots, L$  y siendo  $L$  el número máximo de niveles de gris, la expresión de este estadístico es:

$$C = \sum_{I_m=1}^L \sum_{I_n=1}^L \delta(I_m, I_n) P(I_m, I_n, d)$$

donde  $\delta(I_m, I_n)$  es una medida de no similitud que depende de la característica usada. Esta característica puede ser la intensidad de los niveles de gris

$$\delta = (I_m - I_n)^2$$

o bien la orientación de los puntos de borde:

$$\delta = \text{sen}(|I_m - I_n|)$$

En este caso se empleará la función discriminante para orientación de los puntos de borde.

### Extracción de características

Tras situar la franja de estudio en la zona central de la imagen con dimensiones  $512 \times 256$  pixels, se debe abordar el análisis de la misma. Se hace necesario subdividir esta región en pequeñas ventanas cuyo estudio resulta bastante más sencillo. Por otro lado se consigue discretizar la información de la franja completa, en zonas de dimensiones reducidas sobre las que se extraerá un vector de características en base a los estadísticos definidos con anterioridad.

Adoptando ventanas cuadradas de  $16 \times 16$  pixels se consiguen un total de 512, dispuestas en 16 filas de 32 columnas cada una. En primer lugar se realiza el cálculo de la media aritmética y suavidad relativa, descriptores ambos de primer orden, sobre cada una de las ventanas en que se divide la franja principal de interés.

Para proceder a los cálculos de segundo orden es necesario previamente filtrar la imagen original. El filtro elegido debe ser capaz de acentuar los cambios bruscos de contraste existentes en la escena, pues será precisamente este parámetro el objeto de nuestro estudio. El operador Laplaciana por su calidad de filtro derivador, paso alto por consiguiente, resulta adecuado para este propósito.

Dicho operador actúa sobre campos escalares, extrayendo la suma de las distintas derivadas parciales de segundo grado con respecto a las variables espaciales que intervienen. Denotando por  $V$  al campo escalar en cuestión, la expresión del operador Laplaciano queda:

$$\frac{\partial^2 V}{\partial x^2} + \frac{\partial^2 V}{\partial y^2} + \frac{\partial^2 V}{\partial z^2}$$

La imagen filtrada presenta las condiciones idóneas para llevar a cabo el estudio del contraste sobre cada una de las ventanas definidas en la misma, previo cálculo de la matriz de co-ocurrencia correspondiente.

Debe remarcarse la necesidad de obtener la matriz de co-ocurrencia de cada ventana antes de calcular el contraste.

1  
2  
3  
4  
5  
6  
7  
8  
9  
10  
11  
12  
13  
14  
15  
16  
17  
18  
19  
20  
21  
22  
23  
24  
25  
26  
27  
28  
29  
30  
31  
32  
33  
34  
35  
36  
37  
38  
39  
40  
41  
42  
43  
44  
45  
46  
47  
48  
49  
50  
51  
52  
53  
54  
55  
56  
57  
58  
59  
60  
61  
62  
63  
64  
65  
66  
67  
68  
69  
70  
71  
72  
73  
74  
75  
76  
77  
78  
79  
80  
81  
82  
83  
84  
85  
86  
87  
88  
89  
90  
91  
92  
93  
94  
95  
96  
97  
98  
99  
100  
101  
102  
103  
104  
105  
106  
107  
108  
109  
110  
111  
112  
113  
114  
115  
116  
117  
118  
119  
120  
121  
122  
123  
124  
125  
126  
127  
128  
129  
130  
131  
132  
133  
134  
135  
136  
137  
138  
139  
140  
141  
142  
143  
144  
145  
146  
147  
148  
149  
150  
151  
152  
153  
154  
155  
156  
157  
158  
159  
160  
161  
162  
163  
164  
165  
166  
167  
168  
169  
170  
171  
172  
173  
174  
175  
176  
177  
178  
179  
180  
181  
182  
183  
184  
185  
186  
187  
188  
189  
190  
191  
192  
193  
194  
195  
196  
197  
198  
199  
200  
201  
202  
203  
204  
205  
206  
207  
208  
209  
210  
211  
212  
213  
214  
215  
216  
217  
218  
219  
220  
221  
222  
223  
224  
225  
226  
227  
228  
229  
230  
231  
232  
233  
234  
235  
236  
237  
238  
239  
240  
241  
242  
243  
244  
245  
246  
247  
248  
249  
250  
251  
252  
253  
254  
255  
256  
257  
258  
259  
260  
261  
262  
263  
264  
265  
266  
267  
268  
269  
270  
271  
272  
273  
274  
275  
276  
277  
278  
279  
280  
281  
282  
283  
284  
285  
286  
287  
288  
289  
290  
291  
292  
293  
294  
295  
296  
297  
298  
299  
300  
301  
302  
303  
304  
305  
306  
307  
308  
309  
310  
311  
312  
313  
314  
315  
316  
317  
318  
319  
320  
321  
322  
323  
324  
325  
326  
327  
328  
329  
330  
331  
332  
333  
334  
335  
336  
337  
338  
339  
340  
341  
342  
343  
344  
345  
346  
347  
348  
349  
350  
351  
352  
353  
354  
355  
356  
357  
358  
359  
360  
361  
362  
363  
364  
365  
366  
367  
368  
369  
370  
371  
372  
373  
374  
375  
376  
377  
378  
379  
380  
381  
382  
383  
384  
385  
386  
387  
388  
389  
390  
391  
392  
393  
394  
395  
396  
397  
398  
399  
400  
401  
402  
403  
404  
405  
406  
407  
408  
409  
410  
411  
412  
413  
414  
415  
416  
417  
418  
419  
420  
421  
422  
423  
424  
425  
426  
427  
428  
429  
430  
431  
432  
433  
434  
435  
436  
437  
438  
439  
440  
441  
442  
443  
444  
445  
446  
447  
448  
449  
450  
451  
452  
453  
454  
455  
456  
457  
458  
459  
460  
461  
462  
463  
464  
465  
466  
467  
468  
469  
470  
471  
472  
473  
474  
475  
476  
477  
478  
479  
480  
481  
482  
483  
484  
485  
486  
487  
488  
489  
490  
491  
492  
493  
494  
495  
496  
497  
498  
499  
500  
501  
502  
503  
504  
505  
506  
507  
508  
509  
510  
511  
512  
513  
514  
515  
516  
517  
518  
519  
520  
521  
522  
523  
524  
525  
526  
527  
528  
529  
530  
531  
532  
533  
534  
535  
536  
537  
538  
539  
540  
541  
542  
543  
544  
545  
546  
547  
548  
549  
550  
551  
552  
553  
554  
555  
556  
557  
558  
559  
560  
561  
562  
563  
564  
565  
566  
567  
568  
569  
570  
571  
572  
573  
574  
575  
576  
577  
578  
579  
580  
581  
582  
583  
584  
585  
586  
587  
588  
589  
590  
591  
592  
593  
594  
595  
596  
597  
598  
599  
600  
601  
602  
603  
604  
605  
606  
607  
608  
609  
610  
611  
612  
613  
614  
615  
616  
617  
618  
619  
620  
621  
622  
623  
624  
625  
626  
627  
628  
629  
630  
631  
632  
633  
634  
635  
636  
637  
638  
639  
640  
641  
642  
643  
644  
645  
646  
647  
648  
649  
650  
651  
652  
653  
654  
655  
656  
657  
658  
659  
660  
661  
662  
663  
664  
665  
666  
667  
668  
669  
670  
671  
672  
673  
674  
675  
676  
677  
678  
679  
680  
681  
682  
683  
684  
685  
686  
687  
688  
689  
690  
691  
692  
693  
694  
695  
696  
697  
698  
699  
700  
701  
702  
703  
704  
705  
706  
707  
708  
709  
710  
711  
712  
713  
714  
715  
716  
717  
718  
719  
720  
721  
722  
723  
724  
725  
726  
727  
728  
729  
730  
731  
732  
733  
734  
735  
736  
737  
738  
739  
740  
741  
742  
743  
744  
745  
746  
747  
748  
749  
750  
751  
752  
753  
754  
755  
756  
757  
758  
759  
760  
761  
762  
763  
764  
765  
766  
767  
768  
769  
770  
771  
772  
773  
774  
775  
776  
777  
778  
779  
780  
781  
782  
783  
784  
785  
786  
787  
788  
789  
790  
791  
792  
793  
794  
795  
796  
797  
798  
799  
800  
801  
802  
803  
804  
805  
806  
807  
808  
809  
810  
811  
812  
813  
814  
815  
816  
817  
818  
819  
820  
821  
822  
823  
824  
825  
826  
827  
828  
829  
830  
831  
832  
833  
834  
835  
836  
837  
838  
839  
840  
841  
842  
843  
844  
845  
846  
847  
848  
849  
850  
851  
852  
853  
854  
855  
856  
857  
858  
859  
860  
861  
862  
863  
864  
865  
866  
867  
868  
869  
870  
871  
872  
873  
874  
875  
876  
877  
878  
879  
880  
881  
882  
883  
884  
885  
886  
887  
888  
889  
890  
891  
892  
893  
894  
895  
896  
897  
898  
899  
900  
901  
902  
903  
904  
905  
906  
907  
908  
909  
910  
911  
912  
913  
914  
915  
916  
917  
918  
919  
920  
921  
922  
923  
924  
925  
926  
927  
928  
929  
930  
931  
932  
933  
934  
935  
936  
937  
938  
939  
940  
941  
942  
943  
944  
945  
946  
947  
948  
949  
950  
951  
952  
953  
954  
955  
956  
957  
958  
959  
960  
961  
962  
963  
964  
965  
966  
967  
968  
969  
970  
971  
972  
973  
974  
975  
976  
977  
978  
979  
980  
981  
982  
983  
984  
985  
986  
987  
988  
989  
990  
991  
992  
993  
994  
995  
996  
997  
998  
999  
1000



Llegados a este punto, se ha obtenido un vector de tres características (media, suavidad, contraste) para cada una de las 512 subregiones de la escena de interés. Este vector será necesario para discriminar la naturaleza de la ventana en cuestión.

### Clasificación

El objetivo principal es encontrar qué ventanas presentan rasgos propios de carretera y dónde están ubicadas. Esta información se consigue a raíz del vector de características obtenido con anterioridad.

Debe aclararse que al igual que en otros trabajos de investigación, el móvil portador de la cámara será colocado inicialmente dentro de la carretera. Asimismo se le indicará qué zona de la escena se asume como tal.

Esto tiene por objeto la extracción de características tanto de carretera como de no carretera con el objetivo de tomarlas como punto de partida para todos los cálculos que se realicen en sucesivas iteraciones.

Se asume, por tanto, el conocimiento inicial de todas las ventanas con rasgos de carretera y también de aquellas que presentan características de no carretera. Todas ellas constituyen la base para realizar el siguiente análisis.

Para decidir la pertenencia o no de una ventana a la carretera, se recurre a un aparato matemático que permita clasificar correctamente las 512 ventanas en que se divide la zona de interés. Acudiremos pues, a la teoría del análisis discriminante cuyos puntos fundamentales son los que a continuación se detallan.

**Clases o patrones:** constituyen un vector de posibles modelos a los que puede pertenecer una muestra dada. En nuestro caso tiene 2 componentes, al estar formado exclusivamente por las clases carretera y no carretera. La expresión general de este vector queda de la forma:

$$(\alpha_1, \dots, \alpha_n)$$

**Vector de características:** su contenido es la base para realizar el estudio discriminante y dilucidar a cuál de las clases  $\alpha_1, \dots, \alpha_n$  pertenece la muestra cuyo vector de caracte-




Figura 6.— Patrones matemáticos del 0 al 14.

rísticas se está analizando. Su expresión es:

$$\bar{x} = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$$

Sobre cada muestra o subregión se obtiene un vector de características de tres componentes: media aritmética, suavidad relativa y contraste.

**Función discriminante:** mediante ella se lleva a cabo la separación y clasificación en las distintas clases del vector de patrones. Su expresión general es la que sigue:

$$fd(\bar{x}) = w_1x_1 + w_2x_2 + w_3$$

para un vector de dos componentes  $x_1, x_2$ .

Dado un vector de características cualquiera  $(x_{1a}, x_{2a})$ , la evaluación de la función discriminante debe permitir decidir a qué clase pertenece.

A la hora de definir la función discriminante, existen tres planteamientos básicos, a saber, regionalización del espacio de características, distancia euclídea y enfoque estadístico.

#### — Regionalización del espacio

Esencialmente consiste en la subdivisión del universo de características en regiones de trabajo que deben ser separables. Para ello se

obtiene un clasificador que en función de las salidas proporcionadas por varias funciones discriminantes (una por cada patrón) decide a qué clase pertenece el vector de características analizado.

Su realización parece inviable en este caso debido a la imposibilidad de asignar una región acotada del espacio, para todos los vectores de la clase no carretera.

#### — Distancia Euclídea

Cada vector de características se asocia a la clase más próxima al mismo. Este método exige el cálculo de la distancia existente entre la muestra y el valor medio de cada una de las clases posibles.

Partiendo de la expresión:

$$dE = \sqrt{(\bar{x} - \bar{z}_i)^T (\bar{x} - \bar{z}_i)}$$

$$fd(\bar{x}) = \bar{z}_i^T \bar{x} - \frac{1}{2} \bar{z}_i^T$$

Elevando al cuadrado esta expresión, desarrollando y prescindiendo de términos constantes que no aportan datos diferenciadores, se consigue la siguiente función discriminante:

$$dE = \sqrt{(\bar{x} - \bar{z}_i)^T (\bar{x} - \bar{z}_i)}$$

$$fd(\bar{x}) = \bar{z}_i^T \bar{x} - \frac{1}{2} \bar{z}_i^T$$

que resultará máxima cuando la distancia sea mínima.

No obstante tampoco es aconsejable este planteamiento para el problema que se pretende resolver. La principal dificultad radica en la aparición del vector de características medias de un patrón dado,




Figura 7.— Patrones matemáticos 15 y 16.

puesto que en el caso de la clase no carretera su significado puede ser intrascendente y poco ilustrativo.

Esto es comprensible entendiendo que la varianza entre las características de todas las zonas admitidas como no carretera es muy grande, al englobar como tal texturas de tipos totalmente distintos, siempre y cuando no coincidan con los rasgos propios de carretera.

— Enfoque estadístico

La principal virtud del enfoque estadístico radica en su capacidad de mejorar el reconocimiento para clases solapadas.

El teorema de Bayes constituye el soporte matemático sobre el que se apoya esta teoría, siendo su expresión:

$$p(\alpha_i / \bar{x}) = \frac{p(\bar{x} / \alpha_i) p(\alpha_i)}{p(\bar{x})}$$

donde el denominador de la misma opera como un factor de escala al aparecer en todas las clases.

$\alpha_i$  representa a la clase  $i$ -ésima y el vector  $\bar{x}$  contiene las características de la ventana que se pretende clasificar.

Dadas las clases  $\alpha_1, \dots, \alpha_n$  y un vector de parámetros se resuelve el problema calculando las distintas probabilidades de que dicho vector pertenezca a cada una de las clases posibles, resultando elegida aquella para la que la probabilidad obtenida resulte mayor, prescindiendo del factor de escala.

Paralelo hay que conocer la función densidad de probabilidad de las muestras, que se supondrá NORMAL.

$$f(x) = \frac{1}{(2\pi)^{n/2} \det[C_i]} * \exp - \frac{1}{2} (\bar{x} - \bar{m}_i)^T C_i^{-1} (\bar{x} - \bar{m}_i) * p(\alpha_i)$$

donde  $C_i$  es la matriz de covarianza de todas las muestras de una clase dada y  $m_i$  el vector de medias de las mismas.

Se trata de un problema de estimación estadística en el que la hipótesis normal es aceptada en el 99% de los casos reales.

Tomando neperianos sobre la función densidad de probabilidad y desarrollando el resultado, se llega a una expresión del tipo:

$$dE = \sqrt{(\bar{x} - \bar{z}_i)^T (\bar{x} - \bar{z}_i)}$$

El tercer sumando puede desprejarse bajo ciertas hipótesis con lo que se obtiene una función discriminante lineal. Dichas hipótesis consisten en que todas las clases sean equiprobables y que las matrices de covarianza de las muestras que las forman sean iguales. El discriminador resultante se puede asemejar a un discriminador por distancia euclídea.

Este resulta el enfoque más adecuado para realizar la clasificación entre los patrones carretera y no carretera, ya que a pesar de que puedan existir solapamientos y que la región propia de las muestras pertenecientes a no carretera sea muy dispersa, el discriminador Bayesiano permite separar entre las diversas clases atendiendo a sus funciones de densidad de probabilidad condicionada, que resultan estar bastante diferenciadas.

Cálculo de funciones discriminantes

Se acepta como válido el discriminador Bayesiano asumiendo que la distribución de los vectores de características para ambos patrones presenta forma Gaussiana. Pruebas prácticas han demostrado posteriormente que así es.

Existen dos opciones para realizar la clasificación mediante este método: calcular la función discriminante con aprendizaje y hallar dos funciones densidad de probabilidad, una para cada clase.

— Procedimiento con aprendizaje

Se dispone de objetos etiquetados, conociéndose de antemano a qué clase pertenecen.

$$dE = \sqrt{(\bar{x} - \bar{z}_i)^T (\bar{x} - \bar{z}_i)}$$

pertenecientes a las clases  $\alpha_1, \dots, \alpha_n$ . De cada patrón se tendrá un conjunto de elementos que permitirá obtener de forma apriorística la función discriminante. El aprendiz modifica sus parámetros hasta que el error tiende a cero. El número de muestras presentadas debe ser suficientemente grande como para que esto ocurra.

Denotando por  $k$  al número de elementos con los que se construirá la función del aprendiz emplearemos los siguientes términos:

-Función de decisión:

$$dE = \sqrt{(\bar{x} - \bar{z}_i)^T (\bar{x} - \bar{z}_i)}$$

donde  $w$  es un vector cuyas componentes se ven modificadas en cada paso del aprendizaje hasta conseguir los valores óptimos, y  $k$  representa el número de iteración.

-Función de error:

$$dE = \sqrt{(\bar{x} - \bar{z}_i)^T (\bar{x} - \bar{z}_i)}$$

$$fd(\bar{x}) = \bar{z}_i^T \bar{x} - \frac{1}{2} \bar{z}_i^T$$

$fd_s$  representa la función de decisión del supervisor, que será la fun-



ción densidad de probabilidad de una distribución normal cuya expresión aparece en la sección anterior.

Se trata de minimizar el error de una función en la que  $w$  aparece al cuadrado, por lo que hablaremos de error cuadrático. Cada ensayo se aproxima al mínimo obedeciendo la siguiente regla de modificación:

$$w(k+1) = w(k) - \mu(k) \frac{dJ}{dw} |_{w(k)}$$

el factor  $\mu(k)$  es fundamental para conseguir la convergencia hasta  $w_{\text{óptima}}$ . Para lograr cambios rápidos para valores altos, pasando a valores pequeños cuando se requiera un acercamiento progresivo al punto óptimo.

Este aprendizaje es válido para clasificaciones en dos tipos o patrones. Para un conjunto de clases la expresión de recurrencia anterior se generaliza así:

$$\bar{w}(k+1) = \bar{w}(k) - \mu(k) \nabla_w J(\bar{w}) |_{\bar{w}(k)}$$

donde:

$$\nabla = \begin{pmatrix} \frac{\partial}{\partial w_1} \\ \vdots \\ \frac{\partial}{\partial w_{n+1}} \end{pmatrix}$$

Concretando para el caso de un discriminador Bayesiano la función de evaluación queda:

$$p(\bar{x} / \alpha_i) p(\alpha_i) = \bar{w}^T \bar{x}$$

aceptando como válida la suposición de que las matrices de covarianza son iguales, como resulta aceptable en la práctica.

Denotando por  $e$  al error cometido en cada iteración, la ley recurrente resulta:

$$\bar{w}^i(k+i) = \bar{w}^i(k) + \mu(k) \bar{x}(k) \text{signo}(e)$$

o bien

$$\bar{w}^i(k+1) = \bar{w}^i(k) + \mu(k) \bar{x}(k) e(k)$$

Conviene usar la primera ecuación para comenzar y posteriormente la segunda para lograr un ajuste fino.

Se justifica el enfoque aprendizaje cuando no exista separación lineal entre las clases, como ocurre entre los patrones carretera y no carretera. Al aplicar el método sobre imágenes reales, los resultados son válidos pero aparecen otros problemas. Calcular una función discriminante con aprendizaje sobre 512 ventanas implica un tiempo que puede aumentar excesivamente el período de muestreo, con el consiguiente riesgo de pérdida de estabilidad en el seguimiento.

Cálculo de varias funciones densidad

Esta opción supone un modo alternativo de clasificación basada en la misma teoría discriminante Bayesiana y cuya eficacia ha sido respaldada por resultados prácticos.

Se calcula una función densidad de probabilidad para cada clase. Su expresión es la ecuación general de una distribución Gaussiana comentada en secciones anteriores.

$$f(x) = \frac{1}{(2\pi)^{N/2} \det[C_i]} \exp - \frac{1}{2} (\bar{x} - \bar{m}_i)^T C_i^{-1} (\bar{x} - \bar{m}_i) * p(\alpha_i)$$

La imagen inicial contiene información sobre la naturaleza de todas las ventanas que la componen. Atendiendo a la misma se calculan las matrices de covarianzas y valores medios para ambas clases, empleando todas las muestras de las mismas que aparezcan en escena. Se presupone, por tanto, una distribución normal para ambos patrones.

La clasificación de muestras, en posteriores iteraciones del algoritmo, exige calcular el valor que toma el vector de características de las mismas sobre las dos funciones densidad de probabilidad conseguidas. La ventana se asigna a la clase cuyo valor resulte máximo.

Para iteraciones posteriores a la primera, el cálculo se realiza sobre las 512 subregiones de la zona de

estudio, consiguiendo clasificarlas en carretera y no carretera. Es importante recordar que el clasificador requiere la información de la primera imagen y que toma ésta como base para el estudio de posteriores escenas.

Sea  $x$  el vector de características de una muestra dada,  $f_1(x)$  la función densidad de probabilidad para la clase carretera y  $f_2(x)$  la función densidad de probabilidad para la clase no carretera, la forma de discriminar es la siguiente:

$$f(x) = \frac{1}{(2\pi)^{N/2} \det[C_i]} \exp - \frac{1}{2} (\bar{x} - \bar{m}_i)^T C_i^{-1} (\bar{x} - \bar{m}_i) * p(\alpha_i)$$

en caso contrario la ventana es asignada a la clase no carretera.

La Figura 4 muestra las operaciones realizadas hasta que una muestra es asignada a una clase dada.

La Figura 5 muestra varios ejemplos de clasificaciones a partir de imágenes reales, siguiendo este procedimiento de cálculo.

Conseguida la segmentación de la imagen dentro de la franja de interés en 512 ventanas, clasificadas en carretera y no carretera, se presenta el problema de decidir la trayectoria a la que responde la carretera.

### Patrones preestablecidos

Es necesario hablar del número y naturaleza de las salidas establecidas. Se definen 17 posibles trayectorias que intentan cubrir el margen dinámico de los cambios posibles de la carretera (curvas, rectas) al ser recorrida por un móvil.

Los patrones definidos se enumeran de [0,...,16] y son creados según los criterios que a continuación se detallan: consideremos una línea de horizonte y un par de rectas que fugan sobre la misma. El triángulo formado entre ellas y una recta que las intersecte con dirección paralela a la línea de horizonte constituye el patrón básico de carretera que se emplea. La trayectoria que describe es la dirección de la bisectriz del ángulo que forman las dos rectas iniciales al cortarse.

Para su aplicación práctica se adopta como línea de horizonte la línea superior de la zona de interés y como base del triángulo que describen los patrones empleados, la línea inferior de la misma zona.

## Visión artificial

Los patrones que van del 10 al 14 se definen de este modo, siendo su numeración y posición la que muestra la Figura 6.

Las salidas 15 y 16 están previstas para casos en los que aparezca una curva muy pronunciada en la trayectoria, bien a derechas o a izquierdas. Por esto su definición matemática varía con respecto al resto de los patrones.

Se emplea una curva cuadrática que partiendo de uno de los vértices inferiores de la zona de estudio (derecho para curvas a izquierdas e izquierdo en caso contrario) recorra la misma hasta llegar al lado opuesto. Estos patrones parabólicos asemejan bastante la forma real de la visión que tiene el móvil de las curvas cerradas. La Figura 7 ilustra convenientemente la forma de los mismos.

Se pueden seguir dos caminos para determinar cuál de las 17 salidas definidas es tomada como la trayectoria correcta: cálculo probabilístico y redes neuronales.

### Cálculo probabilístico

El método es sencillo y consiste en encontrar cuál de los patrones guarda una mayor similitud con la imagen segmentada. Para ello se realiza una comparación lineal con la misma. Como sabemos, la zona de estudio se divide en 512 subregiones que tendrán valor 0 cuando hayan sido asignadas a la clase no carretera y 1 en caso contrario. Se trata de realizar las siguientes operaciones para cada una de las 17 posibles salidas.

Sobre la zona de interés segmentada se recorre el área definida por los límites de cada patrón en cuestión, contando el número de ventanas con valor 1 que se encuentran dentro de la misma.

Para evitar problemas debidos a las pequeñas diferencias de superficie entre patrones, el número hallado se normaliza dividiendo entre el total de ventanas que abarca la zona recorrida. De esta forma se obtiene la probabilidad de que la trayectoria de la imagen estudiada sea la descrita por el patrón analizado. Efectuado el cálculo sobre los 17 modelos resulta elegido aquél que presente probabilidad máxima.

A pesar de lo intuitivo, el sistema de cálculo de probabilidades plantea varios problemas que hacen dis-

minuir su porcentaje de eficacia notablemente, según contrastan pruebas prácticas. Estas dificultades derivan de la posición de la cámara que porta el móvil, de la ubicación relativa de éste dentro de la calzada y de su escasa capacidad para clasificar segmentaciones pobres correspondientes a imágenes de carreteras con baches y sombras.

En su lugar se opta por el uso de redes neuronales que permiten paliar los problemas anteriores mediante la realización de un entrenamiento adecuado.

### Redes neuronales

Las redes neuronales pueden entenderse como sistemas muy flexibles de clasificación de patrones. Constituyen sistemas de reconocimiento de tipo no paramétrico, es decir, para su desarrollo no es necesario conocer las funciones de densidad de probabilidad condicionada de los ejemplos a clasificar.

Todos los modelos de ANN (artificial neural net) desarrollados hasta el momento presentan elementos comunes, tales como:

— Unidades de procesamiento: la unidad básica de procesamiento es la neurona artificial. Cada neurona artificial posee una o más entradas y una única salida. Recibe un conjunto de entradas y produce una salida, aplicando una función umbral. Pueden ser de entrada (externas a la red), de salida (transfieren información hacia el exterior) y ocultas (reciben entradas y envían su salida a otras unidades de la red).

— Estado de activación: es la representación en cada momento "t" del estado del sistema, pues cada unidad  $U_i$ , posee un patrón de activación  $a_i(t)$ .

— Función de salida o de transferencia: asociada a cada unidad  $U_j$ , existe una función 'f' que a partir del estado de activación de la neurona, produce una señal de salida  $S_j$ . Es a esta función a la que se le denomina de transferencia.

— Patrón de conectividad entre unidades: las conexiones que unen a las neuronas tienen asociado un peso. Al conjunto de pesos de una ANN se le denomina patrón de conectividad. Cada peso individual se denota por  $w_{ij}$ , que es el peso de la unión entre la neurona  $U_i$  y la  $U_j$ .

— Regla de propagación: establece una combinación lineal entre los valores de entrada y los pesos asociados a las conexiones de entrada a la neurona  $U_j$ .

$$f(x) = \frac{1}{(2\pi)^{N/2} \det[C_i]} * \exp -$$

$$- \frac{1}{2} (\bar{x} - \bar{m}_i)^T C_i^{-1} (\bar{x} - \bar{m}_i) * p(\alpha_i)$$

donde  $w_{ij}$  son los pesos de las conexiones que llegan a la neurona  $U_j$  y  $S_i$  la salida que se produce en aquellas neuronas que están conectadas a las entradas de la neurona  $U_j$ .

— Regla de activación: se utiliza una función 'F' que produce un nuevo estado de activación a partir del ya existente ( $a_j$ ) y la combinación de las entradas con los pesos asociados ( $net_j$ ).

— Regla de aprendizaje: en esta fase se realiza el ajuste de los pesos de las conexiones de la red con el fin de que ésta realice las asociaciones de la manera deseada.

— Funcionamiento de la red: a grandes rasgos se puede describir como sigue. Se calcula el valor de  $net_j$  a partir de los pesos de las entradas que llegan a la neurona. A partir del mismo y del estado actual se obtiene el nuevo estado de activación, que será pasado como parámetro a la función 'f' para calcular la salida de la neurona.

El proceso de aprendizaje para redes de este tipo consiste en suministrar un patrón a la entrada de la red y comparar el resultado proporcionado por las unidades de salida, con la salida deseada.

Seguidamente se reajustan los pesos de la red de tal forma que, la próxima vez que se presente el mismo patrón, la red produzca un resultado más cercano al deseado, esto es, que disminuya el error.

Este método suele denominarse propagación del error hacia atrás (Back Propagation) o regla delta generalizada.

La regla delta aplicada al perceptrón consiste en ajustar los pesos según la expresión:

$$f(x) = \frac{1}{(2\pi)^{N/2} \det[C_i]} * \exp -$$

$$\text{donde } \delta_j = O_j - S_j$$

$S_j$  es la salida que se produce en la unidad  $U_j$ ,  $O_j$  es el objetivo de salida,  $I_j$  es el valor a la entrada de

neurona  $U_j$  y  $\alpha$  es un índice de aprendizaje.

El método es aplicable a la regla delta generalizada solo que el cálculo de  $\delta_j$  varía ligeramente.

Si  $U_j$  es una unidad de salida, entonces:

$$\delta_j = (O_j - S_j) * f_j'(net_j)$$

$$net_j = \sum w_{ij} * S_i$$

La diferencia radica en el término derivada de la función de salida.

b) Si  $U_j$  no es una neurona de salida:

donde el rango  $k$  cubre todas

$$\delta_j = f_j'(net_j) * \sum_k \delta_k * w_{kj}$$

aquellas unidades a las que está conectada la salida  $U_j$ .

Queda por ver la función de transferencia 'f' que en redes multicapa suele ser de tipo sigmoideal:

$$f(x) = \frac{1}{1 + e^{-x}}$$

El método del gradiente necesita un número infinito de pasos infinitesimales para obtener efectivamente un mínimo local. Cuanto mayor es el valor de  $\alpha$ , mayor es la modificación de los pesos en cada iteración, pudiendo originarse oscilaciones. Al objeto de filtrar esas oscilaciones se añade un momento, quedando la expresión:

$$\Delta w_{ji}(t+1) = \alpha * \delta_j * S_i + \beta * \Delta w_{ji}(t)$$

$\beta$  es una constante que determina el efecto en  $t+1$  del cambio de pesos en el instante  $t$ . Con este momento se consigue la convergencia de la red en menor número de iteraciones.

#### a) Descripción de la red

La red que se ha utilizado en nuestro caso es de propagación hacia adelante con tres capas de neuronas: entrada, oculta y salida. La función de transferencia es de tipo sigmoideal; siendo la función de activación la función identidad. El algoritmo de aprendizaje es el de retropropagación de gradiente.

La red consta de 512 neuronas de entrada. Cada neurona corresponde a una ventana de la zona de interés, pudiendo valer 1 cuando fue clasificada como carretera ó 0 en caso contrario. La capa de salida de la red tiene una única neurona que proporciona un valor analógico que va de 0 a 1.

Para discernir entre cada una de las salidas deseadas, se divide el margen dinámico de la salida en 17 intervalos que corresponden al número de trayectorias que la red puede clasificar. La capa oculta de la red está formada por 18 neuronas, resultando esta cantidad idónea para conseguir que el sistema aprenda correctamente.

#### b) Fase de aprendizaje

Durante el aprendizaje se le enseñaron a la red un total de 170 imágenes segmentadas con 512 ventanas, 10 por cada una de las trayectorias posibles.

Los parámetros óptimos conseguidos en el entrenamiento son:

- $\alpha = 0,25$
- $\beta = 0,1$
- Ancho zona sigmoideal: 0,8
- Desviación máxima: 0,03
- Neuronas capa oculta: 18
- Neuronas salida: 1

Después de 213 ciclos la red converge y queda entrenada correctamente. Es necesario constatar que la eficacia de la red dependerá del número de patrones con que haya sido entrenada y de la calidad y variedad de los mismos, aumentando de forma proporcional con respecto a estos factores.

#### c) Ejemplos de funcionamiento

Cuando se introducen imágenes reales segmentadas la red produce salidas que satisfacen la trayectoria que se describe realmente, tal y como muestra la figura 8.




Figura 8.— Trayectoria final obtenida sobre imagen real.

aplicación específica, dado que solo tienen en cuenta en el aprendizaje el valor de las entradas en un instante de tiempo, sin considerar su historia pasada. Para mejorar las prestaciones, sin renunciar al patrón conexionista, se está probando un modelo de redes neuronales que trata de incorporar la dinamicidad de las entradas.

Esta red tiene la habilidad de aprender relaciones entre los datos entrantes actuales y los eventos pasados, además de aprender relaciones entre estos eventos pasados. Cada unidad recibe el valor de un conjunto de señales para el instante presente y la historia temporal de la misma.

Considerando una red TDNN multicapa con un retardo  $k\tau$  en la conexión  $k$ , el nivel de activación para la unidad  $j$ , con el patrón, es:

$$a_j^\mu(t) = f[S_j^\mu(t)]$$

donde

$$S_j^\mu(t) = \sum_{i=1}^F \sum_{k=0}^F w_{j,i,k} * a_i^\mu(t - k\tau)$$

siendo  $f(x)$  una función simétrica.

La regla de aprendizaje y ajuste de pesos, sigue el paradigma de la retropropagación del error. Se emplea la regla delta generalizada, sirviendo el término del momento para acelerar la convergencia:

$$\Delta w_{j,i,k}(t) = \mu \delta_{j,i}^\mu(t) * a_i^\mu(t - k\tau) + \alpha \Delta w_{j,i,k}(t-1)$$

### Redes neuronales con retardo

Las redes neuronales, compuestas por unidades simples interconectadas, son atractivas para estas tareas, por ofrecer procedimientos de diseño automático y ser capaces de acomodar condiciones de diseño muy restrictivas.

Sin embargo, los resultados siguen siendo dependientes de la

Existen dos modos de conseguir la invarianza con el desplazamiento usando este tipo de red. El primero exige realizar un entrenamiento, en el que deben aparecer los distintos patrones de entrada duplicados y desplazados ligeramente. De esta forma se muestran a la red las posibles situaciones en las que pueden aparecer éstos.

Sin embargo, este método necesita un número de patrones desplazados que depende del número de clases y de la cantidad de ruido que soporta el sistema, entre otros factores.

La otra posibilidad consiste en hacer que los pesos de "bias", pesos adicionales de cada capa, sean función del desplazamiento y de los otros pesos:

$$w_{j0} = - \sum_i \sum_j S_i * w_{j,i,k}$$

donde  $S_i$  es la cantidad de desplazamiento en el canal  $i$ .

$$S_j^\mu(t) = a_0 * w_{j,0} + \sum_i \sum_{k=0}^{d_i} w_{j,i,k} * a_i^\mu(t-kt)$$

donde

$$a_i^\mu(t) = a_i^\mu(t) + S_i$$

## Adaptación del sistema

La trayectoria calculada sirve de consigna a la etapa de control que guía al móvil, y que no es objeto de este estudio. El lazo de realimentación que se establezca debe servir para evitar que el reconocimiento pierda su eficacia ante variaciones de las características de la carretera.

Se hace necesario, por ello, recurrir nuevamente al análisis discriminante. El objetivo es obtener las nuevas características de la imagen estudiada de forma que sirvan como patrón de clasificación en la siguiente iteración del algoritmo. La forma de actuar es la siguiente.

Conocida la trayectoria, se recorre la superficie delimitada por sus bordes característicos tomando como carretera todas las muestras que se hallen dentro de la misma y anotando sus características.

Se extraen también los vectores de características del resto de ventanas de la imagen, que se asumen como pertenecientes a la clase no carretera.

Con la base de datos así formada se procede al cálculo de las funciones densidad de probabilidad para las dos clases a clasificar. Estas funciones son empleadas como discriminadores en la siguiente iteración para conseguir la clasificación. De esta forma, si el período de muestreo es suficientemente pequeño se logra seguir la trayectoria que marca una carretera, a pesar de que las características de la misma varíen, pues son actualizadas en cada paso del algoritmo. □

*the Carnegie-Mellon Navlab. IEEE Trans. on Pattern Analysis and Machine Intelligence, Vol 10, No. 3, May 1988.*

[4] S. Zhang and B.T. Thomas. *Knowledge-Based Vehical Navigation in Complex Road Network. IFAC 1993.*

[5] J. Manigel and W. Leonhard. *Vehicle Control by Computer Vision. IEEE Trans. on Industrial Electronics, vol 39, No. 3, June 1992.*

[6] M. Mazo and D. Maravall. *Guidance of an Autonomous Vehicle by Visual Feedback. Cybernetics and Systems. An International Journal, 21:257-266. 1990.*

## REFERENCIA

161

## Referencias

[1] E. Dickmanns and A. Zapp. *Autonomous high-speed road vehicle guidance by computer vision. In Proc. 10th IFAC, Munich, 1987.*

[2] D. DeMenthon. *Inverse Perspective of a Road from a Single Image. Technical Report CAR-TR-210, University of Maryland, 1986.*

[3] Charles Thorpe, Martial H. Hebert. *Vision and Navigation for*