

Apéndice D

Aprendizaje de conductas locales de navegación

D.1 Introducción

Existen dos tipos básicos de enfoques para controlar la navegación de un robot móvil: técnicas globales y locales. En las técnicas globales, como son los métodos geométricos, la programación dinámica o los métodos de campo de potencial (ver en (Latombe 1991) resumen y referencias complementarias) se asume totalmente conocida la descripción geométrica del entorno en el que se va a mover el robot. Se trata de métodos potentes y eficaces para generar tanto trayectorias a seguir como secuencias de comandos a ejecutar. Son métodos usados para el control de robots que trabajan en entornos sin ninguna variabilidad y que realizan tareas repetitivas en las que se conocen en todo momento el valor de todas sus variables de estado.

Los métodos locales o reactivos, por el contrario, consideran que el robot va a moverse en un entorno no conocido a priori y proporcionan unas conductas estándar para reaccionar ante lecturas de los sensores del robot (evitar obstáculo, seguir pared, entrar en puerta, alinearse con objeto, etc.). Estas conductas (o *esquemas* en la terminología de Arkin (Arkin 1990)) son aplicables en gran número de entornos distintos y se suelen usar junto con un control de alto nivel que se encarga de secuenciarlas. Este tipo de control es el que vamos a utilizar en el presente trabajo.

D.1.1 Técnicas previas para el control local

Entre las propuestas de control local, cabe destacar el enfoque del *histograma de campo vectorial* (Borenstein y Korem 1991), el método de velocidad-curvatura (Simmons 1996), el

Método de control local	Esquemas
Histograma de campo de potencial	avanzar-evitando-obstáculos ir-a-objetivo entrar-por-puerta
Velocidad-Curvatura	avanzar-evitando-obstáculos ir-a-objetivo
Ventana Dinámica	avanzar-evitando-obstáculos ir-a-objetivo
Esquemas motores	esquemas configurables

Tabla D.1: Esquemas de actuación susceptibles de ser implementados con cada uno de los métodos de control local. Ver en el texto principal las referencias correspondientes a cada uno de los métodos.

método de ventana dinámica (D.Fox, Burgard, y Thrun 1997) y el método del propio Arkin de esquemas motores (Arkin 1989).

En la tabla D.1 se comparan el tipo de esquemas de conducta susceptibles de ser implementados usando cada uno de estos enfoques. El enfoque de esquemas motores, pese a ser el más genérico, es muy complejo de llevar a la práctica por el gran número de parámetros que deben ser ajustados en las ecuaciones de control del robot. El mismo problema plantea el enfoque del histograma de campo de potencial. Un problema añadido de ambos métodos es que obtienen los comandos del robot en dos fases separadas. En la primera fase se obtiene la dirección objetivo en la que debe moverse el robot. En la segunda fase se generan los comandos de modificación de las velocidades lineales y angulares necesarios para conducir al robot en la dirección deseada. Este enfoque sólo es factible si consideramos que las aceleraciones aplicables al robot son infinitas y el robot puede realizar de forma instantánea los incrementos de velocidades. Sin embargo, la realidad es que las aceleraciones usadas en la navegación de robots móviles debe ser baja para obtener trayectorias suaves y no forzar a la estructura mecánica del robot a tensiones excesivas.

Por otra parte, los enfoques de Simmons y Fox han demostrado ser capaces de controlar con éxito robots móviles que actúan en entornos de oficina con gran cantidad de obstáculos y personas en movimiento (una universidad en el primer caso, y un museo en el segundo). Sin embargo, se trata de propuestas difícilmente generalizables a otro tipo de esquemas de conducta distintos de la evitación de obstáculos, como puede ser el seguimiento de una pared, la localización de esquinas o la localización y entrada en puertas abiertas.

Hay que hacer notar también que en todos estos enfoques se trabaja con información proporcionada por sensores de rango de baja densidad y limitado alcance, como son los ultrasonidos. Esto provoca, entre otros, el problema de ambigüedad en la percepción denominado *perceptual aliasing*, en el que situaciones del robot distintas, en las que se deberían tomar acciones también distintas, se solapan en una misma percepción.

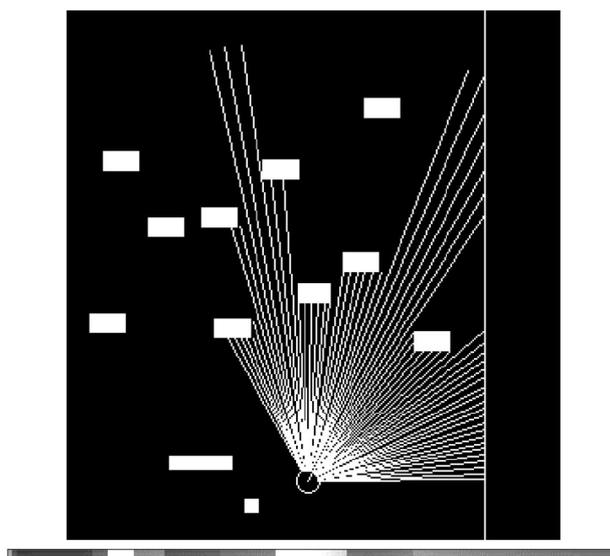


Figura D.1: Una muestra del simulador sobre el que se ha realizado la experimentación del artículo. En la parte inferior de la figura se incluye el mapa de profundidad captado por el robot. Tonos de gris oscuros corresponden con lecturas de profundidad cercanas.

D.1.2 Control local basado en reconocimiento estadístico de situaciones

En línea con las propuestas de Arkin y Chapman (Chapman 1991), la acción a ejecutar vendrá indexada por el esquema de conducta activo en ese momento y por la situación del entorno percibida por el robot. En la propuesta que presentamos en este trabajo formulamos el problema del control local de un robot móvil como un problema de reconocimiento de situaciones. Asociado a cada uno de los esquemas de actuación definimos un conjunto de acciones aplicables y aprendemos las situaciones de percepción en las que esas deben aplicarse.

Para obtener muestras de aprendizaje de un funcionamiento correcto del esquema optimizamos una función que considera la trayectoria seguida por el robot, tanto en el espacio cartesiano como en el espacio de velocidades lineales y angulares, y que premia trayectorias consistentes con el esquema. Por ejemplo, para un esquema *seguir-pared* consideramos que la distancia cartesiana a la pared debe ser pequeña y uniforme, premiando aquellas trayectorias con mayores velocidades lineales. Dado que el espacio de búsqueda es enorme, y que la función a optimizar no es susceptible de ser diferenciada, utilizamos para su resolución la técnica de algoritmos genéticos, diseñando una codificación de las trayectorias del

robot y un método de cruzamiento que han demostrado tener una alta efectividad.

A partir de las trayectorias obtenidas se generan todas las parejas de percepción y acción que el robot ha ido encontrando en la misma, y se agrupan en situaciones percibidas para un mismo tipo de acción.

La dimensionalidad del espacio de percepción debe ser alta para poder establecer diferencias entre las pautas de percepción asociadas a distintos esquemas de conducta. Por ello utilizamos como entrada percibida el campo denso de profundidad existente frente al robot móvil. Aunque hemos desarrollado el trabajo sobre un simulador (ver figura D.1), existen técnicas que permiten obtener este campo de profundidad en tiempo real mediante técnicas actuales de visión artificial (ver (Kanade, Kano, Kimura, Yoshida, y Oda 1995) como ejemplo de utilización de visión estéreo).

Una forma de caracterizar estas situaciones es utilizar un técnica estadística estándar como es el Análisis de Componentes Principales (Fukunaga 1990) para reducir la dimensionalidad de las muestras de aprendizaje correspondientes a cada situación. Veremos que el análisis de componentes principales permite reducir los mapas densos de profundidad a unos pocos parámetros en los que se mantienen la identidad propia de cada situación y que pueden utilizarse de forma efectiva para el reconocimiento.

D.2 Aprendizaje y clasificación de situaciones

Una vez se han generado un conjunto de trayectorias correctas para el esquema que se está aprendiendo, utilizando el método propuesto en el apéndice anterior, se trata de caracterizar las situaciones en las que el robot se va a encontrar cuando evolucione siguiendo ese esquema.

Modelamos el estado en el que puede encontrarse un robot móvil evolucionando por un entorno mediante: 1) un mapa de denso de profundidad observado por el robot $d(\theta)$ y 2) las velocidades lineales y angulares del mismo (v y ω). Definimos un mapa denso de profundidad como el vector $d(\theta)$, que nos indica la distancia a la que se encuentra el obstáculo más cercano en la orientación θ (considerando como 0 la orientación frontal). La obtención de estos mapas de profundidad es inmediata en el simulador. Los límites del ángulo θ vienen dados por las características de la cámara. Para el presente artículo hemos variado θ entre -45 y 45 grados.

A partir de las trayectorias generadas por algoritmo genéticos se generan los estados que ha encontrado el robot en su evolución siguiendo dichas trayectorias. Estos estados se agrupan en conjuntos de situaciones prototipo que son aprendidos y reconocidos de la forma que se explica a continuación. Un ejemplo de campos de profundidad asociado a una situación determinada (en concreto, velocidad lineal del robot entre 60 y 70 cm/s) se presenta en la figura D.2. Cada fila de la figura corresponde al mapa de profundidad en un instante de tiempo.

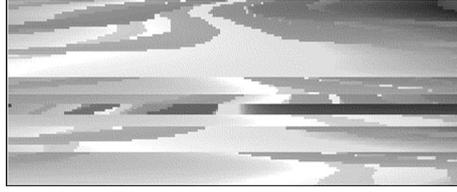


Figura D.2: Ejemplo del conjunto de muestras de entrenamiento de la situación correspondiente a v_{60} ($v \in [60\text{cm/s}, 70\text{cm/s}]$). Cada fila de la figura corresponde al mapa de profundidad en un instante de tiempo.

D.2.1 Análisis de Componentes Principales

El análisis de componentes principales ha sido utilizado con éxito recientemente en la comunidad de visión artificial para representar imágenes de caras humanas (Sirovich y Kirby 1997) y para reconocer imágenes de caras (Turk y Pentland 1991). Con esta técnica se calculan los autovectores del conjunto de muestras de alta dimensionalidad y son usados como base ortogonal para representar cada una de las muestras individuales. Estos autovectores constituyen la dimensión de un subespacio de muestras, denominado el *autoespacio*, en el que las muestras se pueden representar de forma compacta. Utilizaremos este enfoque aplicándolo al conjunto de mapas de profundidad de cada una de las situaciones.

Representamos, pues, esta distribución de mapas de profundidad mediante una función de perturbación alrededor de un mapa de profundidad medio correspondiente a la situación:

$$d(\theta) = d_0(\theta) + \rho(\theta) \quad (\text{D.1})$$

donde $\rho(\theta)$ son pequeñas fluctuaciones $\rho/d_0 < 1$ que capturan la identidad de cada una de las muestras. El mapa de profundidad medio se calcula a partir de las muestras de entrenamiento correspondientes a la situación

$$d_0(\theta) = \frac{1}{N} \sum_{i=1}^n d_i(\theta) \quad (\text{D.2})$$

Para representar $\rho(\theta)$ de cada situación realizamos un análisis de las componentes principales y se expanden las fluctuaciones en términos de un conjunto de autovectores Ψ_l extraídos a partir de cada distribución siguiendo el procedimiento estándar (Fukunaga 1990).

$$d(\theta) = d_0(\theta) + \sum_l a_l \Psi_l(\theta) \quad (\text{D.3})$$

De esta forma, un mapa denso de profundidad correspondiente a una situación determinada pasa a representarse como una combinación lineal de los modos de variación más

importantes (Ψ_l) sumado al mapa de profundidad medio. Por ello, considerando el nuevo espacio paramétrico definido por los modos de variación principales, un mapa de profundidad pasa a representarse por el vector $b = (b_1, \dots, b_l)$ correspondiente a las coordenadas en el nuevo espacio paramétrico, reduciéndose considerablemente la dimensionalidad de la distribución. Los autovalores λ_l asociados a cada uno de los autovectores representan la varianza de cada uno de los modos de variación principales.

D.2.2 Clasificación

La proyección b de un mapa de profundidad d en un autoespacio P_l se obtiene mediante la ecuación

$$b = P_l^T (d - d_0), \quad (\text{D.4})$$

siendo $P_l = [\Psi_1, \dots, \Psi_l]$ la matriz con los l primeros autovectores.

Una métrica muy usada para cuantificar la pertenencia de una muestra a una distribución es la distancia de Mahalanobis, que mide la distancia de la muestra al centro de una distribución, ponderada por la varianza en cada uno de las dimensiones del espacio: D_{Mah} :

$$D_{\text{Mah}}(b, \lambda) = \sum_{k=1}^l \left(\frac{b_k^2}{\lambda_k} \right) \quad (\text{D.5})$$

El criterio usado para medir a que situación pertenece un mapa de profundidad percibido es escoger aquella situación cuyo autoespacio minimiza la distancia de Mahalanobis con el mapa de profundidad percibido:

$$\text{situación actual} = \min_{i=0}^t D_{\text{Mah}}(b_i, \lambda_i), \quad (\text{D.6})$$

siendo t el numero de situaciones aprendidas, b_i la proyección del mapa de profundidad actual en el autoespacio correspondiente a la situación i y λ_i los autovalores de la situación i .

D.3 Resultados

Se ha realizado una implementación del esquema avanzar-evitando-obstáculos siguiendo la propuesta del trabajo. Para ello se han generado comportamientos correspondientes a ese esquema en distintos entornos aleatorios.

A partir de estas trayectorias hemos considerado 8 situaciones correspondientes a velocidades lineales ($v_{10}, v_{20}, \dots, v_{80}$), con v_i agrupando las velocidades lineales en el rango (i cm/s, $i + 10$ cm/s), y 3 situaciones correspondientes a velocidades angulares ($\omega_{-10}, \omega_0, \omega_{10}$),



Figura D.3: Ejemplo del conjunto de muestras de entrenamiento de las situaciones correspondiente a v_{50} , v_{60} y v_{70} .

con ω_i agrupando las velocidades angulares en el rango ($i - 5$ grados/s, $i + 5$ grados/s). Se han obtenido muestras de los mapas de profundidad percibidos por el robot en cada una de estas situaciones (en la figura D.2 se puede observar un ejemplo de los mapas de profundidad asociados las situaciones v_{50}, v_{60} y v_{70}).

Se ha realizado un análisis de componentes principales de las muestras correspondientes a cada una de las situaciones, obteniéndose el autoespacio asociado a cada una de ellas. En la figura D.4 se muestran los mapas de profundidad medios correspondientes a las situaciones v_{10}, \dots, v_{80} . En ellos se representa la distancia media (en centímetros) a la que se encuentran obstáculos (desde -45 grados hasta 45 grados en dirección frontal) cuando el robot se movía a la velocidad correspondiente a cada una de las situaciones. Se puede ver que es coherente con lo esperado: a velocidades más altas el robot se encuentra los obstáculos a mayor distancia.

Por último, la figura D.5 muestra un ejemplo de evolución del robot utilizando el reconocimiento de situaciones propuesto anteriormente. Cada $0,2$ segundos se realiza una lectura del mapa de profundidad del entorno, se proyecta esa lectura sobre los autoespacios correspondientes a cada una de las situaciones aprendidas y se obtiene la velocidad lineal y angular a la que debería estar moviéndose el móvil (aquellas con las que se minimiza su distancia de Mahalanobis), modificándose las velocidades actuales consecuentemente.

D.4 Conclusiones

Se ha presentado un enfoque con el que es posible aprender automáticamente esquemas locales de conducta que guían la navegación de un robot móvil, aplicándose al ejemplo concreto de avanzar evitando obstáculos. El método se puede resumir en: 1) generación off-line de trayectorias consistentes con el esquema de navegación, 2) aprendizaje de las situaciones de percepción (mapas densos de profundidad) que el robot se ha encontrado cuando estaba

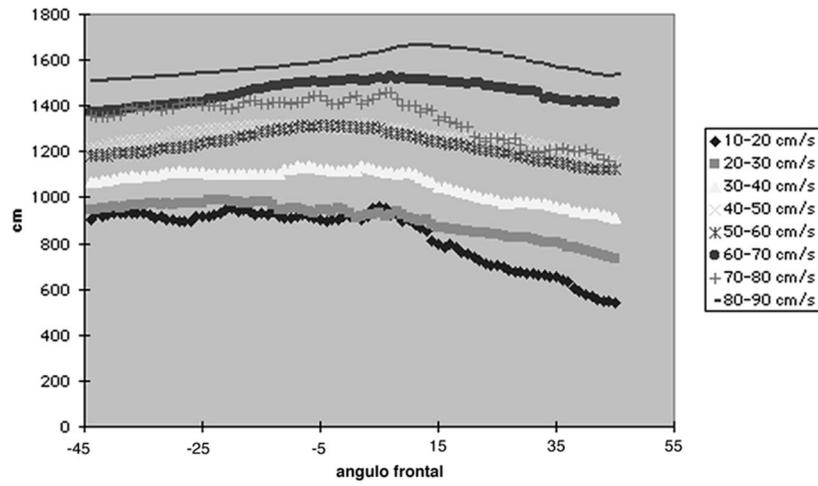


Figura D.4: Mapas de profundidad medios correspondientes a cada una de las distintas situaciones de velocidad lineal.

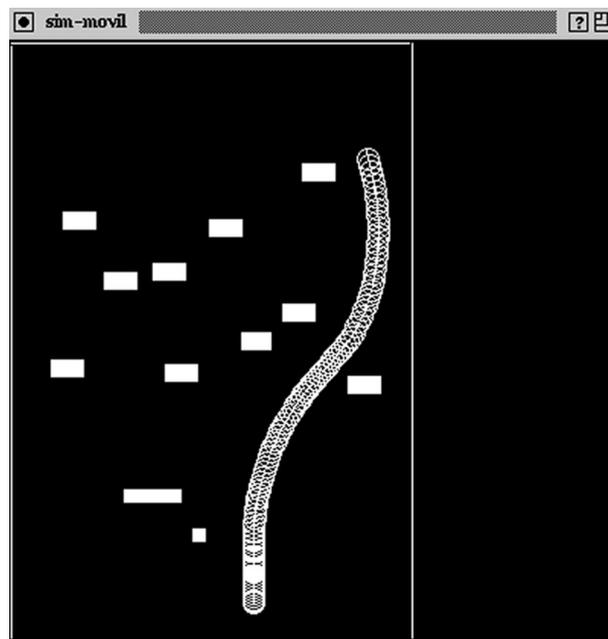


Figura D.5: Ejemplo de trayectoria seguida por el robot aplicando el algoritmo de control basado en reconocimiento estadístico de situaciones.

evolucionando en el entorno, agrupados por situaciones discretas (robot moviéndose entre 10 y 20 cm/s, robot moviéndose entre 20 y 30 cm/s, etc.) y 3) control del robot basado en el reconocimiento de situaciones.

El primer aspecto se ha llevado a cabo utilizando técnicas de algoritmos genéticos, el segundo con un análisis de componentes principales y el tercero utilizando las distancias a las distribuciones aprendidas.

Como trabajo futuro, estamos comenzando a caracterizar otros esquemas utilizando estas técnicas (como seguir-pared o entrar-en-puerta) al tiempo que pretendemos comprobar la validez del planteamiento en un robot real.

