

## Integración sensorial utilizando clasificación difusa en tareas de ensamblado en robótica

J.A. García Muñoz<sup>a</sup>, M.A. LLama Leal<sup>b</sup> y J.A. Padilla Medina<sup>a</sup>

<sup>a</sup> Instituto Tecnológico de Celaya,

Av. Tecnológico y A. García Cubas, 38010, Celaya, Gto.

<sup>b</sup> Instituto Tecnológico de la Laguna,

Blvd. Revolución y Czda. Cuauhtémoc, 27000, Torreón, Coah.

Recibido el 1 de abril de 2004; aceptado el 17 de mayo de 2004

Se han desarrollado algunas propuestas para la automatización de tareas de ensamblado con robots. Sin embargo, casi todas enfrentan el mismo problema: la necesidad de identificar la situación de contactos actual a partir de la información sensorial. La confiabilidad de las tareas de ensamblado con manipuladores robóticos es afectada por la incertidumbre. El conocimiento de las fuerzas de reacción es complemento natural de la información de configuración geométrica en presencia de incertidumbre, ya que implican una restricción en el espacio de configuraciones del robot. Las técnicas de integración sensorial tienen como objetivo combinar la información de diversos sensores para construir y actualizar un modelo del entorno que permita alcanzar una meta determinada. En este trabajo se presenta una propuesta de integración sensorial, basada en técnicas de clasificación difusa, que utiliza el conocimiento de la configuración del robot y las fuerzas generalizadas de reacción, considerando la incertidumbre de modelado y sensado.

*Descriptores:* Identificación de estados; clasificación difusa; manipulación diestra.

Some approaches to the automation of assembly tasks with robots have been proposed. However, nearly all of them face the same problem: the need of identifying the current contact situation from sensory data. The confidence of assembly tasks with robotic manipulators is affected by uncertainty. The knowledge of the generalized reaction force is the natural complement to configuration information in the presence of geometric uncertainty, since a reaction force indicates a constraint in Configuration Space. Sensorial integration techniques have as objective to use information provided for several sensors to build and update a world model in order to achieve a goal. In this paper we present an approach to multisensory integration based on fuzzy c-means clustering algorithm for detection and identification of states during a dexterous manipulation task in robotics, considering modeling and sensing uncertainties.

*Keywords:* State identification; fuzzy clustering; dexterous manipulation.

PACS: 07.07.Tw

### 1. Introducción

En la actualidad los robots se programan para realizar tareas específicas en ambientes altamente estructurados. Como se prevén con anticipación todos los detalles, la realimentación sensorial prácticamente no es necesaria. Sin embargo, para mantener la competitividad, las celdas de manufactura deben tener capacidad de reconfigurarse según se requiera. Esto dificulta el diseño de ambientes estructurados que soporten una gran cantidad de tareas eficientemente.

El empleo de sensores permite a un sistema inteligente obtener información sobre sí mismo y el ambiente que le rodea, modificando su comportamiento de acuerdo a las características del estado percibido. Las técnicas de integración sensorial tienen como objetivo combinar la información procedente de diversos sensores para construir y actualizar un modelo del entorno que permita alcanzar una meta determinada. La adición de técnicas de integración sensorial hacen al sistema más complejo, pero presenta grandes ventajas frente al procesamiento individual de la información de cada sensor [1]. A partir de la combinación de datos sensoriales es posible derivar información que no podría obtenerse con el análisis de la lectura individual de cada sensor. Esta combinación de información permite además reducir errores generados por la falla de algún sensor, su operación fuera del campo

o la incorrecta interpretación de datos. Además, la redundancia de la información permite el empleo de procesamiento paralelo, con lo que se consigue una extracción más rápida de los datos [2].

Los primeros trabajos sobre técnicas de integración sensorial datan de la década de los ochenta. Henderson y Fai [3] analizaron el empleo de sistemas multisensoriales en reconocimiento de patrones, y Henderson y Shilcrat [4] proponen la *especificación de sensores lógicos* como una metodología para organizar sistemas multisensoriales de manera que se consiga una integración correcta y adecuada de los datos. Desde entonces se han propuesto una gran variedad de sistemas de integración sensorial basadas en pruebas de hipótesis mediante modelos bayesianos [5], matriz de distancias de confianza [6], estimación mediante criterios de costo y desempeño, Zheng, [7], estimación de costo mediante la teoría de decisión bayesiana [8] y mediante filtros de Kalman [9]. La mayoría de estos sistemas están basados en técnicas estadísticas, por lo que los sensores trabajan adecuadamente en ambientes estáticos. Basañez [10] presenta una clasificación general de estos métodos.

Algunas otras técnicas se basan en métodos heurísticos, inteligencia artificial [13] o redes neuronales artificiales [12] que proporcionan un medio directo para la combinación de

información sin requerir de técnicas estadísticas, lo que los hace apropiados para su aplicación en ambientes dinámicos.

En el presente trabajo se presenta una propuesta de integración sensorial para el reconocimiento de estados en una tarea de ensamblado mediante la aplicación de la técnica de agrupación de C-promedios difusos (*Fuzzy c-means*) utilizando como función objetivo la distancia Euclidiana y la distancia de Mahalanobis. Esta técnica de agrupación difusa fue desarrollada por Bezdek en 1981 [11] y ha sido empleada [14] para el procesamiento de imágenes de resonancia magnética, para segmentación de imágenes a color [15] para clasificar señales acústicas provenientes de diferentes fuentes [16], entre otros.

## 2. Información de fuerzas de reacción

En ausencia de incertidumbre, la información sobre la configuración geométrica del manipulador es suficiente para planificar y ejecutar una tarea de ensamblado. Sin embargo, cuando la incertidumbre geométrica es relevante, esta información generalmente no es suficiente, aunque sigue siendo fundamental. Algunas incertidumbres geométricas pueden modelarse e incluirse en el proceso de diseño de planificación de la tarea.

Las principales fuentes de incertidumbre geométrica en manipulación robótica son:

- a) Tolerancias en la forma y tamaño de los objetos.
- b) Imprecisiones en la ubicación de los objetos en el espacio de trabajo.
- c) Imprecisión en la posición y orientación del robot.
- d) Imprecisión en la posición del objeto dentro de la pinza del robot.

Todas estas fuentes de incertidumbre se combinan en el espacio físico y determinan regiones de incertidumbre donde podrían ubicarse los vértices, bordes y caras de cada objeto. El conocimiento de las fuerzas de reacción generalizadas es el complemento natural de la información de configuración geométrica en presencia de incertidumbre, ya que las fuerzas de reacción implican una restricción en el espacio de configuraciones del robot.

Como se muestra en la Fig. 1, es posible determinar una situación de contacto con base en la observación de las fuerzas de reacción. La dirección de una fuerza generalizada de reacción se ve afectada por las fuentes de incertidumbre geométrica y por las imprecisiones del sensor de momento/fuerza. La Fig. 2 muestra 6 de las 12 posibles configuraciones de contacto en un plano entre un vástago cilíndrico y un orificio.

Es posible asociar los datos de configuración geométrica con incertidumbre con los datos de las direcciones de las fuerzas generalizadas de reacción. Este conjunto conformará las características que determinan el estado actual de la tarea. La planificación de una tarea consistirá entonces en llegar al estado final, partiendo del estado actual percibido por los sensores y pasando por una serie de estados intermedios.

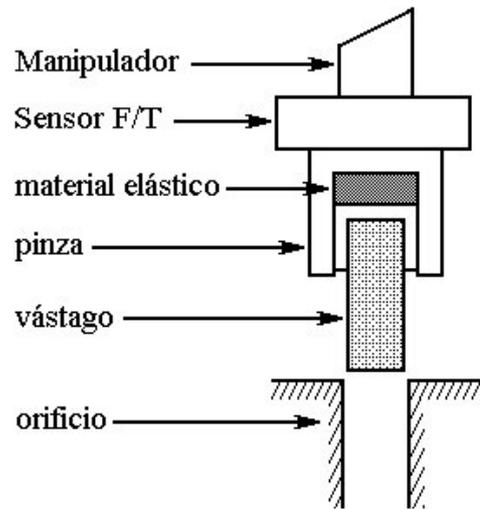


FIGURA 1. Pinza y sensor de fuerza.

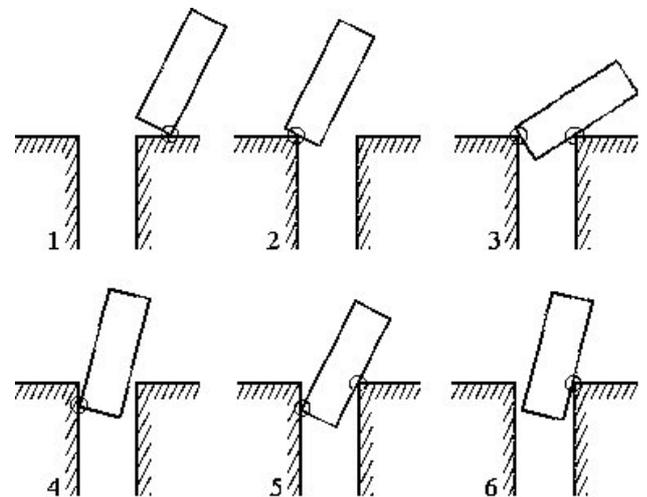


FIGURA 2. Algunas configuraciones de contactos.

Para realizar eficazmente una tarea de ensamblado en presencia de incertidumbre, el manipulador deberá realizar una serie de movimientos tratando de acomodar las piezas para su correcto ensamblado. Estos movimientos de acomodación estarán restringidos en el espacio por las fronteras entre los objetos y serán determinados por el estado caracterizado por la información sensorial. El empleo de técnicas de acomodación, ya sea pasiva o activa, permite realizar movimientos restringidos en presencia de incertidumbre mediante un mapeo de las fuerzas de reacción a movimientos de corrección.

Algunos trabajos recientes en cuanto a la identificación de contactos incluyen el empleo de redes neuronales para integración de fuerza y medidas de posición [18], fusión de fuerza y visión mediante sistemas expertos [19], clasificación mediante reglas difusas de patrones de momento/fuerza obtenidos de los sensores [20], entre otras técnicas.

### 3. Modelado de los contactos

Representando una operación de ensamblado mediante la de inserción de un vástago cilíndrico sin chafán en un orificio, se observan tres diferentes etapas: la etapa de aproximación, la de búsqueda y la de inserción.

La fase de aproximación consiste en el movimiento libre del manipulador, sin contacto con entidades de su ambiente, por lo que solamente requiere del control convencional de posición. La fase de búsqueda se inicia en cuanto se detecta una fuerza de reacción en la punta de la herramienta. Es durante esta fase que se toman medidas de fuerza y posición que permiten determinar el estado de la tarea. La fase de inserción es la etapa final de la tarea de ensamblado, y matemáticamente, el aspecto más complejo de la operación.

En un ensamble planar, los contactos entre el vástago y el orificio tienen lugar en uno o dos puntos. El diagrama de cuerpo libre del plano Z-X para la configuración 5 mostrada en la Fig. 2, se muestra en la Fig. 3. Para un vástago cilíndrico y una tarea de ensamble tridimensional, puede obtenerse un diagrama similar para el plano Z-Y.

Suponiendo que los cuerpos son infinitamente rígidos y de masa despreciable, se tiene en equilibrio cuasi-estático para esta posición de dos contactos:

$$\begin{aligned}\sum f_x = 0 &= f_x + f_1 \cos \theta - \mu f_1 \sin \theta - f_2, \\ \sum f_z = 0 &= f_z - f_1 \sin \theta - \mu f_1 \cos \theta - \mu f_2, \\ \sum M = 0 &= M - f_x L - f_z \frac{d}{2} + \mu f_2 d + f_2 l.\end{aligned}\quad (1)$$

Combinando estas ecuaciones obtenemos

$$\frac{M}{F} = \sin \alpha \left[ L - \frac{D(\mu \cos \theta + \sin \theta) + d \left( \frac{\mu^2 - 1}{2} \sin 2\theta - \mu \cos 2\theta \right)}{1 - (\mu \sin \theta - \cos \theta)^2} \right] + \cos \alpha \left[ \frac{d + D(\mu \sin \theta - \cos \theta)}{1 - (\mu \sin \theta - \cos \theta)^2} - \frac{d}{2} \right]. \quad (2)$$

Para la configuración 3 de la Fig. 2, que se muestra en la Fig. 4, se tiene:

$$\begin{aligned}\sum f_x = 0 &= f_x - \mu f_1 - f_2, \\ \sum f_z = 0 &= f_z - f_1 + \mu f_2, \\ \sum M = 0 &= M - \mu f_1 L - f_1 \left( \frac{d}{2} - l_1 \right) \\ &\quad - \mu f_2 \frac{d}{2} - f_2 (L - l_2),\end{aligned}\quad (3)$$

$$\begin{aligned}\frac{M}{F} &= \sin \alpha \left[ L + D \frac{\mu \cos \theta - \sin \theta}{\mu^2 + 1} \right] \\ &\quad + \cos \alpha \left[ -\frac{d}{2} + D \frac{\cos \theta - \mu \sin \theta}{\mu^2 + 1} \right].\end{aligned}\quad (4)$$

El análisis geométrico para las configuraciones con un solo contacto es similar; sin embargo, algunas de estas configuraciones pueden quedar indeterminadas debido a la imposibilidad de ubicar con exactitud el punto de contacto. No obstante, presentan una característica común con la que es posible distinguirlas: su razón momento/fuerza es más grande que para las configuraciones de dos contactos.

### 4. Agrupaciones

El agrupamiento (*clustering*) es una metodología para encontrar estructuras naturales en un conjunto de datos muestreados. La colección de muestras con características similares se agrupan formando clases.

Cuando ocurre un traslape entre clases es posible obtener una mejor descripción de los datos mediante técnicas de clasificación difusa, como podría ocurrir con los datos reportados por los sensores de fuerza y configuración geométrica en tareas de ensamblado con incertidumbre.

Las propiedades de los datos muestreados se identifican numéricamente mediante un conjunto de características que forman el espacio de las mismas. Si identificamos los eventos y características que distinguen a cada estado en una tarea de manipulación, podremos construir un espacio de características para cada estado.

Una característica  $F$  es un conjunto de números reales  $f$  que corresponden a todos los valores posibles para esa característica y  $\Phi$  representará el estado actual en una tarea de manipulación. Definimos un espacio euclidiano  $p$ -dimensional que corresponde al producto cartesiano de la familia de características observadas durante ese estado y lo denotamos como

$$\mathbf{F}_{\Phi}^p = F_1 \times F_2 \times \dots \times F_p. \quad (5)$$

En cualquier momento durante un estado tendremos una  $p$ -tupla  $(f_1, f_2, \dots, f_p)$  que corresponde a los valores de la característica actual y define una posición en el espacio de características de dimensión  $p$ . Dentro de este espacio habrá cierto número de regiones  $\xi$  que corresponden a los  $p$  posibles eventos que pueden ocurrir durante el estado.

Los puntos o muestras se conocen como vectores patrón, o simplemente patrones. La colección de todos los patrones

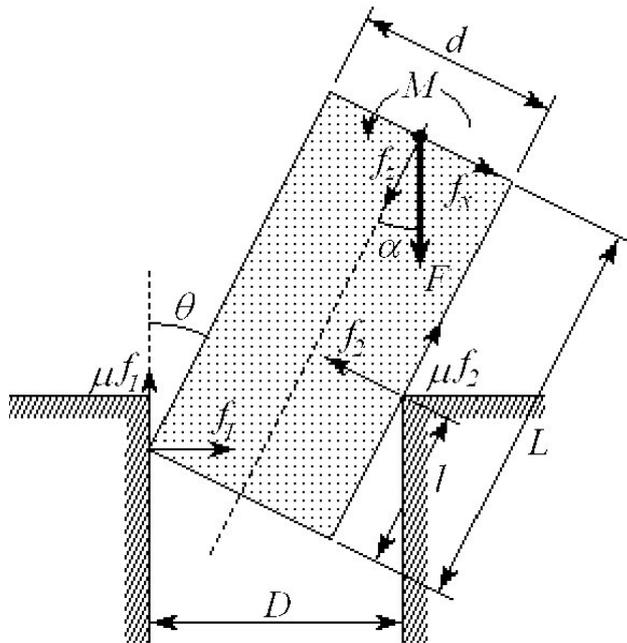


FIGURA 3. Diagrama de cuerpo libre para la configuración 5 de la Fig. 2.

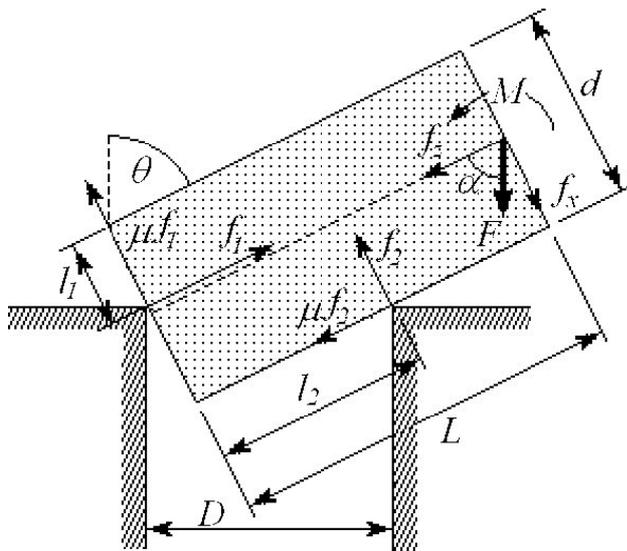


FIGURA 4. Diagrama de cuerpo libre para la configuración 3 de la Fig. 2.

observados conforma el universo denotado por  $X$ . Los elementos individuales de este universo se denotan como  $x_k$ , ( $k= 1, 2, \dots, n$ ), donde  $n$  es el número total de elementos.

**5. C-promedios difusos**

Consiste en un método de agrupación iterativo que separa el conjunto de datos  $X=\{x_1, x_2, \dots, x_n\}$  en  $c$  subconjuntos difusos  $u_i$ , donde  $u_i(x_k)$ , es una función de membresía de  $x_k$  en la clase  $i$ . Los valores  $u_i(x_k)$  son arreglados en una matriz  $U$ . El método consiste en minimizar la suma de la función cuadrada del error definida como

$$J_m(U, z) = \sum_{i=1}^c \sum_{k=1}^n u_{ik}^m d_{ik}^2, \tag{6}$$

donde  $u_{ik}$  es el valor de la  $i$ -ésima función de membresía para el  $k$ -ésimo dato  $x_k$ ,  $U \in M_{fcn}$  es una partición difusa  $c$  de  $X$  y el espacio  $M_{fcn}$  contiene todas las particiones difusas posibles para  $X$ :

$$M_{fcn} = \left\{ U \in \mathbf{R}^{cn} \mid 0 \leq u_{ik} \leq 1 \forall i, k; \sum_{i=1}^c u_{ik} = 1, \forall k; 0 < \sum_{k=1}^n u_{ik} < n \forall i \right\} \tag{7}$$

$z = \{z_1, z_2, \dots, z_c\} \in \mathbf{R}^{cp}$ , con  $z_i \in \mathbf{R}^p$ , es el centro de la agrupación o *prototipo* de la  $i$ -ésima clase;  $d_{ik} = \|x_k - z_i\|^2$ . Empleando la función de distancia euclidiana,  $m$  es un exponente de ponderación o *exponente difuso* tal que  $m \in (1, \infty)$  y afecta la difusividad de  $u$ .

$$d_{ik} = \sqrt{\sum_{j=1}^p (x_{kj} - z_{ij})^2}, \quad (i = 1, 2, \dots, c). \tag{8}$$

Este concepto de proximidad puede ser empleado para determinar los valores de membresía. Las funciones de membresía  $u_1(\cdot), u_2(\cdot) \dots$  se calculan mediante una relación de similaridad basada en la distancia entre las muestras  $x_k$  y los prototipos  $z_i$ :

$$h_i(x_k) = \frac{1}{1 + d_{ik}^2}, i \in \{1, 2, \dots\}. \tag{9}$$

Los valores de  $h_i(\cdot)$  están normalizados para cada muestra, de tal manera que

$$\sum_i u_i(x_k) = 1, \forall k, \tag{10}$$

$$u_i(x_k) = \frac{h_i(x_k)}{\sum_{j \in \{1,2\}} h_j(x_k)}, i \in \{1, 2\}, \forall k. \tag{11}$$

Si no se conocen los prototipos de las clases con anticipación, se emplea un algoritmo de clasificación difusa para estimar las funciones de membresía y los prototipos. El objetivo es encontrar una matriz de partición difusa  $U^*$  y un conjunto de prototipos  $z^*$  que consigan minimizar  $J_m$ . Las condiciones necesarias para minimizar  $J_m$  se obtienen como se muestra en el Apéndice en la Ref. 17, y son

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{jk}}{d_{ik}}\right)^{\frac{2}{m-1}}} \tag{12}$$

y

$$z_i = \frac{\sum_{k=1}^n u_{ik}^m x_k}{\sum_{k=1}^n u_{ik}^m}, \quad \forall i, \tag{13}$$

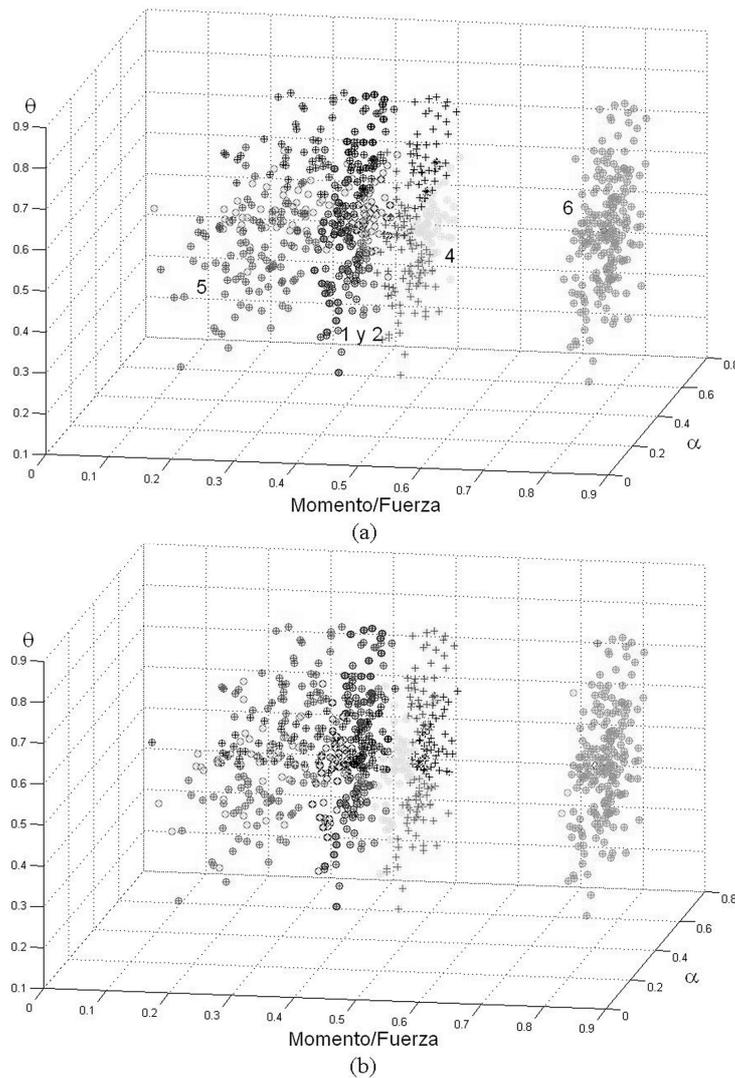


FIGURA 5. Ubicación de datos en escala normalizada utilizando a) distancia de Mahalanobis y b) distancia Euclidiana. Los ángulos  $\alpha$  y  $\theta$  están normalizados en grados/grados.

donde  $m \geq 1$  es el coeficiente que define el grado de difusividad de los conjuntos. Si  $m = 1$  las fronteras entre agrupaciones están bien definidas. A continuación se muestra el algoritmo escrito en pseudocódigo:

```

begin
  Establecer  $c, 2 \leq c \leq n$ ;
  Elegir una norma métrica de producto interno para  $R^P$ .
  Establecer  $m, 1 \leq m \leq \infty$ ;
  Inicializar  $U \in M_{fcn}$ ;
  for  $l := 0$  step 1 until  $maxiter-1$  do
    Calcular los centros de los  $c$  grupos  $\{z_i\}$  con (13) y
     $U$ ;
    Utilizando (11) y  $\{z_i\}$  obtener  $U_{new}$ ;
    if  $\|U_{new}-U\|_{\infty} \leq \varepsilon$  then stop;
     $U := U_{new}$ ;
  end
end.
  
```

Es posible utilizar otras funciones de distancia para obtener los grados de membresía. Una función típicamente empleada, además de la distancia euclidiana es la distancia de Mahalanobis, que se basa en la suposición de que las distribuciones de probabilidad siguen distribuciones normales multivariadas. Estas funciones de densidad describen hiper elipsoides para las cuales existe el lugar geométrico de los puntos cuya función de densidad es la misma y tienen un carácter normalizador de los datos.

### 6. Pruebas y resultados

Se realizaron pruebas en simulación empleando las ecuaciones obtenidas del análisis de fuerzas y momentos presentado en la Sec. 3.

Considerando una barra cilíndrica rígida e indeformable de  $8 \pm 0.040$  cm de longitud por  $2 \pm 0.010$  cm de diámetro a insertarse en un orificio de  $2.2 \pm 0.011$  cm de diámetro, y un sensor de momento/fuerza con una incertidumbre del 10%

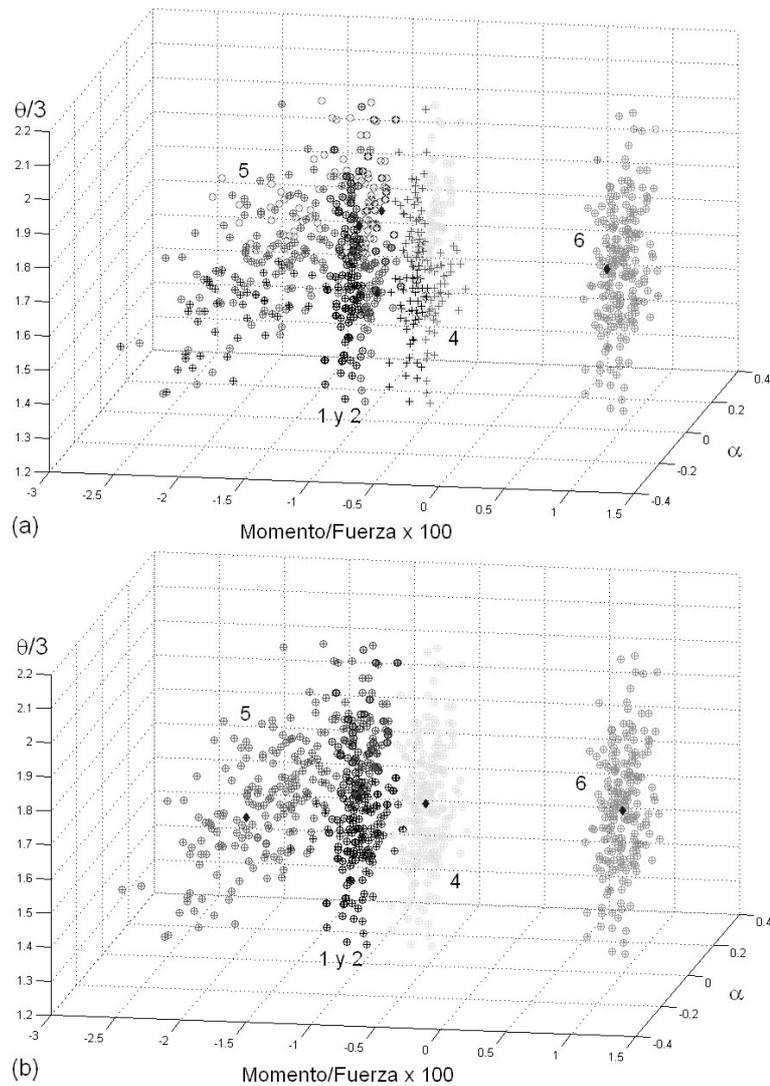


FIGURA 6. Ubicación de datos y prototipos para las configuraciones 1, 2, 4, 5 y 6 con escala especial utilizando a) distancia de Mahalanobis y b) distancia Euclidiana. Los ángulos  $\alpha$  y  $\theta$  están expresados en grados.

del valor medido con un error en la orientación de la barra de  $5^\circ \pm 1\%$ , se tienen las gráficas que se muestran en las Figs. 5 y 6 para las configuraciones 1, 2, 4, 5 y 6 mostradas en la Fig. 2. Para movimientos planares la ubicación del punto de referencia en el extremo del manipulador queda determinado por  $(x_o, y_o)$  con orientación  $\theta_o$ .

La magnitud de las dimensiones en que se expresan los datos es importante para la adecuada clasificación. En la Fig. 5 se muestra una gráfica con valores normalizados de momento/fuerza y ángulos  $\alpha$  y  $\theta$ . En la Fig. 6 se muestra el resultado de la clasificación empleando un escalado de los datos. Se realizaron pruebas utilizando como función objetivo la distancia de Mahalanobis para la identificación de estados (Figs. 5a y 6a), no obstante, bajo las condiciones que se mencionan, se observó una mejor identificación en las pruebas realizadas con la función de distancia Euclidiana (Figs. 5b y 6b).

Se han representado con pequeños círculos las posiciones en el espacio de características obtenidas de las ecuaciones

del sensor de momento/fuerza y de la orientación con incertidumbre  $\theta_0$  para cada estado de la tarea de ensamblado. Las cruces dentro de cada círculo indican el conjunto para el cual ese dato obtuvo el mayor grado de membresía utilizando el algoritmo de clasificación difusa. Los rombos indican la ubicación del prototipo para cada clase.

La configuración 3 no se muestra en las Figs. 5 y 6, ya que puede diferenciarse con más facilidad, porque requiere que el ángulo  $\theta$  sea mayor o igual a 24.6 grados con los datos

TABLA I. Prototipos para las configuraciones 1-2, 4, 5 y 6.

Configuración	M/F	$\alpha$	$\theta$
1-2	-0.010177	0.0129°	4.9494°
4	-0.005275	0.0150°	4.9182°
5	-0.018863	0.0058°	4.7544°
6	0.009997	0.0142°	4.9227°

mencionados anteriormente. Los puntos de fuerza, momento y ángulos  $\alpha$  y  $\theta$  para las configuraciones 1 y 2 son difíciles de separar, ya que las diferencias entre ellos son muy pequeñas, como se muestra en las Figs. 5 y 6. La Tabla I muestra las coordenadas de los prototipos calculados por el algoritmo de clasificación.

## 7. Conclusiones

En este trabajo se propone la aplicación del método de clasificación difusa *fuzzy c-means* para la identificación del estado de una tarea de manipulación utilizando la información sensorial de configuración y fuerzas generalizadas de reacción. En este caso las características que identifican los diferentes estados de la tarea consisten del conjunto de datos sobre configuración geométrica y la información sensorial de las fuerzas/momentos generalizadas de reacción entre las dos entidades en contacto.

Para la adecuada clasificación de los datos, es recomendable que sus dimensiones sean similares en magnitud. En la Fig. 5 se muestra una gráfica con valores normalizados de momento/fuerza y ángulos  $\alpha$  y  $\theta$ , sin embargo, se observa

un mejor resultado multiplicando la relación momento/fuerza por 100, y divide el ángulo  $\theta$  entre 3, como se muestra en la Fig. 6. La elección adecuada de las escalas es importante para una mejor diferenciación en la clasificación de datos.

La clasificación difusa de los datos permite modelar la incertidumbre geométrica y sensorial e identificar los estados de la tarea de una manera rápida y eficiente. Una ventaja respecto a los modelos bayesianos, filtros de Kalman y demás análisis estadísticos reportados en la literatura, es su facilidad de adaptación en ambientes dinámicos y complejos. Por otra parte, el tiempo requerido para el entrenamiento inicial resulta ser menor que el requerido por una red neuronal para el mismo conjunto de datos. Los resultados obtenidos muestran que es posible aplicar esta metodología a tareas en tiempo real, simplificando el conjunto de características, con buenos resultados.

## Agradecimientos

Este proyecto ha sido financiado por el Consejo del Sistema Nacional de Educación Tecnológica CoSNET según convenio CoSNET 664.02-P.

1. R. Bajcsy y P. Allen, *Robotics Research Second Int. Symposium*, ed. H. Hanafusa y H. Inoue, MIT Press (1985) 81.
2. D. Pagac, E.M. Nebot y H.F. Durrant-Whyte, *Reasoning with Uncertainty in Robotics 1995*, 164.
3. T.W. Henderson y W.S. Fai, "MKS: A Multisensor Kernel System", *IEEE Transaction on System, Man and Cybernetics*. **14** (1984) 784.
4. T.W. Henderson y E. Shilcrat, *Journal on Robotics Systems* **1** (1984) 169.
5. H.F. Durrant-Whyte, *International Journal on Robotics Research* **7** (1988) 97.
6. R.C. Luo y M-H. Lin, "Robot multisensor fusion and integration: optimum estimation of fused sensor data", *Proc. IEEE Int. Conf. on Robotics and Automation* (1988).
7. Y.F. Zheng, "Integration of multiple sensors into a robotic system and its performance evaluation". *IEEE Transactions on Robotics and Automation* **5** (1989) 658.
8. J.M. Richardson y K.A. Marsh, *International Journal on Robotics Research* **6** (1988) 78.
9. Y. Nakamura y Y. Xu, "Geometrical fusion method for multi-sensor robotics system", *Proc. IEEE International Conference on Robotics and Automation*, (1989) 668.
10. L. Basañez, "Multisensor Integration in Robotics", *First Workshop on Robotics and CIM*. Lisboa, Portugal (1988).
11. J.C. Bezdek, *Pattern Recognition with Fuzzy Objective Function Algorithms* (Plenum Press, New York 1981).
12. J.C. Pearson, J.J. Gelfand, R.M. Peterson y C.D. Spence, *Proceedings of SPIE* **931**, Sensor Fusion, Orlando, FL. USA (1988) p. 103
13. L. Pau, *Automatica* **25** (1989) 207. Pergamon Press
14. H.-K. Tu, D.B. Goldgof, and E. Backer, *Medical Imaging 1994: Physiology and Function from Multidimensional Images*, *SPIE* **2168** Newport Beach, CA, (February 1994) p. 218.
15. Y.W. Lim y S.U. Lee, "On the Color Image Segmentation Algorithm Based on the Thresholding and the Fuzzy C-Means Algorithm". *Pattern Recognition*, 1990.
16. S.L. Omkar, S. Suresh, T.R. Raghavendra y V. Mani, *Proceedings of the 9<sup>th</sup> International Conference on Neural Information Processing ICONIP'02*, **4** (Singapur, November 18-22) p. 1827.
17. F. Höpner, F. Klawonn, R. Kruse y T. Runkler "Fuzzy Cluster Analysis: Methods for Classification, Data Analysis and Image Recognition". *John Wiley and Sons LTD*. Baffins Lane Chichester, West Sussex, PO12 1UD, England, 1999.
18. G.E. Hovland y B.J. McCarragher, "Combining Force and Position Measurements for the Monitoring of Robotic Assembly" *IEEE/RSJ International Conference on Intelligent Robots and Systems*, Grenoble, France, Sept. 1997
19. R.J. Thien y S.D. Hill, "Fusion of Force and Vision Data for Intelligent Assembly" *IEEE Region 10 Conference Tencon 92*, Melbourne Australia, 11-13 Nov. 1992
20. Skubic M., Volz R.A. "Fuzzy Classification of Contact Formations from Sensor Patterns", *Proceedings of the 1996 U.S.-Japan Graduate Student Forum*, Osaka, Japan, Nov., 1996.