Congr. Int. en Ing. Electrónica. Mem. ELECTRO, Vol. 39, pp. 259-263, Oct 2017, Chihuahua, Chih. México
http://electro.itchihuahua.edu.mx/memorias_electro/MemoriaElectro2017.zip
ISSN 1405-2172

AUTOLOCALIZACIÓN DIFUSA EN ROBÓTICA MÓVIL

Márquez Gutiérrez, Pedro Rafael; García Mata, Carmen Leticia;
Baray Arana, Rogelio; Holguín, Gabriel Adrian
Instituto Tecnológico de Chihuahua
División de Estudios de Posgrado e Investigación del Instituto Tecnológico de Chihuahua
Ave. Tecnológico #2909, Chihuahua, Chihuahua. México, CP 31310
(614) 201-2000, Fax (614) 413-5187
e-mail: {pmarquez, clgarcia, rbaray, gholguin }@itch.edu.mx

RESUMEN.
Se presenta el diseño arquitectural de un sistema de auto-localización difusa para agentes inteligentes físicos móviles. El sistema toma como referencia el esquema clásico probabilístico de autolocalización y lo adapta a la estructura básica de un sistema difuso. Se definen las operaciones difusas requeridas y su semántica, y se compara contra el método probabilístico. Al final se dan conclusiones y trabajo futuro.

1. INTRODUCCIÓN

Un agente inteligente es una entidad capaz de percibir su entorno, analisar sus percepciones y actuar sobre su entorno de manera racional, es decir, de manera correcta y maximizando un resultado esperado. El agente percibe su entorno mediante sensores y actúa sobre su él utilizando actuadores, como se muestra en la Figura 1.

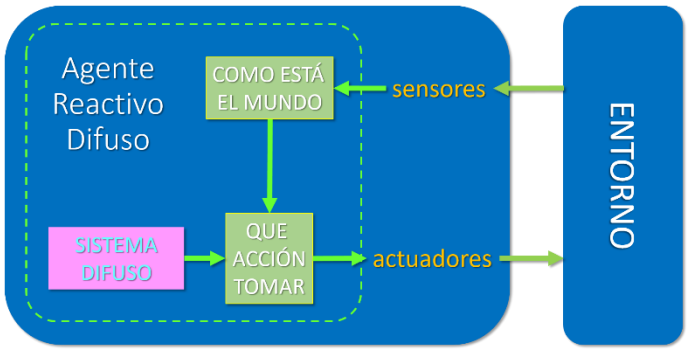

Figura 1. Agente Inteligente Simple

Un agente inteligente puede ser tanto una entidad física como una virtual. El término agente **racional** se refiere a la concepción de agente inteligente como se entiende en Inteligencia Artificial (IA).

Algunas definiciones sobre agentes inteligentes hacen énfasis en su autonomía por lo que prefieren el término de agente inteligente autónomo, mientras que Russell y Norvig, [1], consideran a la *conducta dirigida hacia metas* como la esencia de la inteligencia y prefieren el término tomado de Economía "Agente Racional".

Según Nikola Kasabov [2] y Weiss [3], los sistemas de IA deben exhibir las siguientes características:

- Aprender nuevos problemas e incrementar normas de solución.
- Capacidad de adaptarse en línea y en tiempo real.
- Ser capaces de analizar condiciones en términos de comportamiento, el error y el éxito.
- Aprender y mejorar a través de la interacción con el medio ambiente (realización).
- Aprender rápidamente de grandes cantidades de datos.
- Estar basados en memoria de almacenamiento masiva y la recuperación de dicha capacidad.

Como ejemplos de entidades físicas se encuentran los robots de comportamiento variable autoregulado, software de diagnóstico médico que apoya el quehacer de los galenos, o una computadora que controla un helicóptero en maniobras peligrosas para las personas. Ejemplos de entidades virtuales lo son un software de descubrimiento de patrones en Internet, o un *softbot* que simula a una persona en un juego de computadora.

Como se observa en la Figura 1, el primer problema que debe resolver el agente inteligente consiste en determinar el estado en el cual se encuentra su entorno en el todo momento. En el campo de la robótica móvil, el problema de *autolocalización* es parte del problema. Dado que el agente forma parte de su propio entorno, el agente requiere de un **sistema propioceptivo** que informa al agente de la posición relativa de sus partes corporales, regula la dirección y rango de movimiento, permite reacciones y respuestas automáticas, interviene en el desarrollo del esquema corporal y la relación del agente con su entorno, sustentando la acción motora planificada. Este sistema es abordado básicamente por la Teoría de Control.

Por otro lado, para poder determinar su propia ubicación en el entorno, el agente requiere de un **sistema exteroceptivo**, el cual debe proporcionar información amplia y fiable de la realidad externa.

Los exteroceptores representan los sensores que reciben información del mundo exterior de tipo visual, auditiva, táctil,

etc. En general, aportan información del mundo externo por su reacción con los componentes del mismo. Se considera que la visión es la que más influye en el control motor, ya que cumple con dos funciones: una respecto al objetivo del movimiento o direccional y la otra referente al mismo movimiento que se está realizando, que denominamos formal y que tendría su representación interna en el esquema motor, porque incluye no solo en el mantenimiento de la forma del movimiento, sino la dirección o intención que con el mismo se persigue.

Desafortunadamente, cuando se emplean sensores físicos reales, las mediciones normalmente están afectadas de incertezas de diferentes tipos, como vaguedad, imprecisión, ambigüedad, incompletitud y ruido aleatorio. Además, las mediciones pueden ser afectadas también por factores que ocurren simultáneamente, los cuales no necesariamente son independientes. Por ello, es necesario que esta incerteza se represente cuidadosamente en un sistema robótico. La Lógica Difusa [4] ha demostrado tener herramientas expresivas y técnicas para representar y manejar diferentes facetas de incerteza, que han sido aplicadas en distintos dominios de la robótica como el control difuso [5,6], la modelización difusa [7,8,9], el razonamiento geométrico difuso [10,11], y la fusión de información difusa [12] con éxito.

2. ARQUITECTURA BÁSICA DEL SISTEMA

El enfoque propuesto para el sistema de autolocalización es el de estimación difusa, similar conceptualmente al de estimación probabilística de Markov [13], donde las creencias (*beliefs*) del robot se representan mediante una distribución de probabilidad sobre el espacio de posibles localizaciones. Este enfoque constituye la base de varios métodos de localización actuales que combinan información de múltiples sensores en la forma de mediciones relativas y absolutas para formar una distribución combinada de creencias sobre la ubicación del robot. Aunque este método se basa en estimación Bayesiana, muchos de sus supuestos e ideas son adaptables al marco difuso. En particular, el supuesto Markoviano que establece que el conocimiento acerca del estado actual es independiente del estado futuro y viceversa, similar al cambio de estado en un autómata de estados finitos [14], pero en este caso, estados difusos.

2.1 Ubicaciones Difusas

El espacio continuo de localizaciones probables U puede ser particionado posibilísticamente de manera natural tomando en consideración la ubicación espacial del robot (x, y, z) y su orientación angular (θ, ϕ, η), tal que $\mu: U \to [0,1]$, y $\mu(u)$ es el grado de certeza de que el robot se encuentre en la ubicación espacial u. Por ejemplo, en un espacio 2D, la incerteza asociada con la ubicación del robot se puede representar como $(x \pm \Delta x, y \pm \Delta y)$, donde la imprecisión Δ proviene de la resolución limitada de los sensores, por ejemplo. Esta imprecisión se puede modelar como un conjunto difuso "alrededor de", que a su vez puede ser implementado mediante un conjunto triangular, trapezoidal o de campana, según refleje mejor el desempeño del sensor. Además, la ubicación (x, y) se puede interpretar como $x \wedge y$, donde $\wedge$ es alguna norma-T. Véase la figura 2, donde la incerteza respecto de la resolución del sensor se modelada como una función trapezoidal, y se muestra el resultado de aplicar las normas-T *mínimo* y *producto algebraico*.

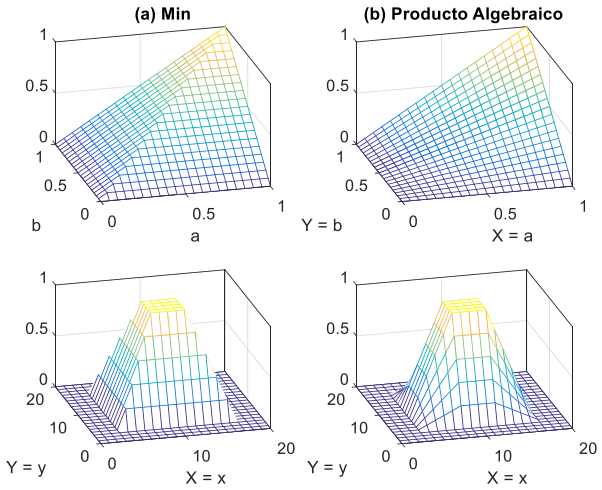

Figura 2. $a = Trap(x, 3,8,12,17)$, $b = Trap(y, 3,8,12,17)$, (a) $T_{\min}(a, b)$, (b) $T_{bp}(a, b)$.

La Base de Conocimiento del robot donde se registra, entre otras cosas, el Estado Actual del Entorno, implica mantener actualizada (consistente) la creencia B_t que tiene el robot acerca de su propia ubicación en el entorno en todo momento, i.e., $B_t: U \to [0,1]$.

2.2 Consistencia de la Ubicación Difusa

Mantener la consistencia de la Base de Conocimiento del agente es necesaria dado la naturaleza lógica de su enfoque, i.e., no deben existir creencias contradictorias que falsifiquen toda inferencia. Esto implica que la creencia que tiene el robot acerca de su ubicación se debe refrendar con las mediciones de sus sensores, lo cual lleva a un enfoque predicción-actualización basado en el modelo de actuación del agente. Es decir, se debe determinar que tan bien se *ajustan* las mediciones a la creencia. De acuerdo a Dougherty [15], el conocimiento acerca de un objeto depende de la forma en la cual lo podemos probar (observar). En particular, la elección de un *elemento de estructuramiento* (una forma o figura) particular influye sobre la información que podemos obtener. Este elemento de estructuramiento se emplea en operaciones morfológicas para el

análisis y procesamiento de estructuras geométricas, como dilatación, erosión y otras.

La dilatación $\oplus$, desarrollada originalmente para imágenes en escala de grises ha sido extendida a *lattices* completos. Sea E un espacio Euclideano D-dimensional $\mathbb{R}^D$, y $B \subset E$ un elemento de estructuramiento, entonces, la dilatación de A y B se define como: $A \oplus B = \cup_{b \in B} A_b$, donde A_b es la traslación de A por b. La Figura 3 muestra la dilatación del cuadrado (en azul marino) por un disco, resultando en el cuadrado (en azul claro) con esquinas redondeadas.

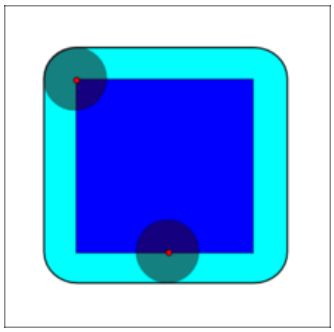

Figura 3. Operación morfológica de dilatación

La morfología matemática difusa [17] ha sido desarrollada empleando la noción de ajuste difuso. El ajuste difuso de un conjunto A en un conjunto difuso B se caracteriza mediante el indicador de inclusión $I(A,B) \in [0,1]$, definido como:

$$I(A,B) = \wedge_{x \in X} \left[1 \wedge \left(1 - \mu_A(x) + \mu_B(x)\right)\right]$$

el cual varía entre 0 (no hay ajuste) y 1 (ajuste perfecto) entre A y B. Empleando $I(A,B)$, el operador de dilatación se define como:

$$\mu_{f \oplus k}(n) = \vee_{m \in K, n-m \in F} \left[0 \vee \left(\mu_k(m) + \mu_f(n+m)\right)\right]$$

donde $\mu_f(n)$ y $\mu_k(n)$ con regiones de soporte F y K son funciones de pertenencia de la señal $f(n)$ y elemento de estructuramiento $k(n)$, respectivamente [16].

La dilatación difusa realiza una transformación global de un subconjunto U de X, aplicando repetidamente una transformación local alrededor de cada $x \in X$. Formalmente, la dilatación de U por B, denotada $U \oplus B$ se define como $(U \oplus B)(x) = \max_{y \in X} T(U(x), B(y-x))$, para alguna norma-T. Intuitivamente, el resultado de la dilatación difusa es una distribución difusa expandida espacialmente a partir de U, donde B determina la forma, como se ilustra en la figura 3. Si B es isotrópico, U se expande en todas direcciones. De esta forma, podemos modelar el movimiento del robot mediante un elemento de estructuramiento B_t, donde $B_t(x)$ representa el grado de certidumbre de que el robot se haya movido a la posición x en el tiempo t, dado que se encontraba en el centro de B en el tiempo $t-1$, i.e., $U_t = U_{t-1} \oplus B_t$.

2.3 Sistema de Ubicación Difusa

La estimación clásica probabilista del estado del agente se realiza de manera recursiva y con base en el filtro de Bayes [18]. Este algoritmo calcula la creencia $bel(x_t)$ en el tiempo t, de que el agente se encuentra en el estado x_t como la probabilidad posterior $p(x_t|z_{1:t}, u_{1:t})$ condicionada por todas las mediciones anteriores $z_{1:t}$ y todos los controles anteriores $u_{1:t}$. De manera análoga, definimos la posibilidad de que el agente se encuentre en la ubicación $x \in X$ dadas las mediciones m en el tiempo t como la función difusa $U_{m,t}: X \rightarrow [0,1]$, la cual representa el grado de certidumbre de que el agente se encuentre en la ubicación x dadas la medición m en el tiempo t. Esta medición m_i es el acumulado de las mediciones individuales de cada sensor i. Esto implica que podemos emplear un operador de agregación o una norma-T en la determinación de su valor [19]. La definición natural es $m = \wedge_{i=1}^{n} m_i$, donde $\wedge(A,B) = T(A,B)$ para alguna norma-T.

Retomando el filtro de Bayes, éste procede en dos pasos básicos. Primero, realiza una operación de *predicción* calculando la integral del producto de la distribución anterior asignada a x_{t-1} por la probabilidad de que el control u_t induzca una transición de x_{t-1} a x_t: $\overline{bel}(x_t) = \int p(x_t|u_t, x_{t-1}) bel(x_{t-1}) dx$. Segundo, se realiza una actualización de las mediciones, multiplicando la creencia $\overline{bel}(x_t)$ por la probabilidad de que la medición z_t haya sido observada: $bel(x_t) = \eta p(z_t|x_t) \overline{bel}(x_t)$, donde η es una constante de normalización.

De manera análoga, podemos implementar un ciclo de estimación difusa para actualizar la creencia posterior $U_t^* = U_t \cap m$, para alguna norma-T. Cabe destacar que la elección de la norma-T dependerá de los supuestos de independencia estadística de las diferentes mediciones. Análoga a la forma de combinar probabilidades de variables aleatorias independientes, una posible norma-T válida es el producto algebraico [19,20].

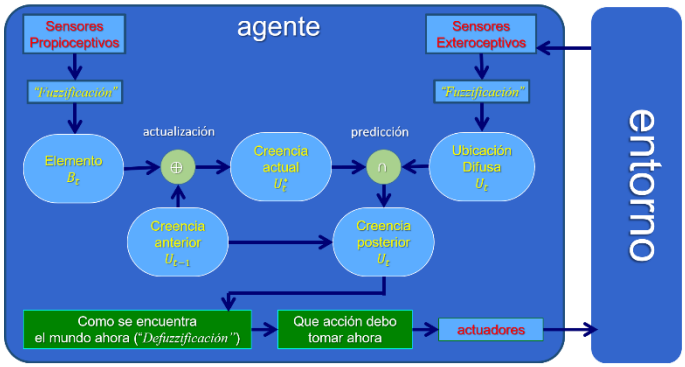

Figura 4. Sistema de Ubicación Difusa

El proceso de ubicación difusa mantiene la estructura de un sistema difuso clásico, como se muestra en la figura 4. Note que el sistema refleja el esquema convencional recursivo predecir-observar-actualizar empleado en la estimación de estados [21]. En el sistema propuesto se pueden observar las tres etapas que constituyen todo sistema difuso: *fuzzificación*-inferencia-*defuzzificación*. Dado que el agente modeliza un robot móvil, las acciones de control se pueden convertir a valores reales mediante un método tipo Sugeno, ilustrado esquemáticamente en la figura 5, el cual es computacionalmente eficiente y ha demostrado ser efectivo con técnicas de optimización y adaptativas, que lo ha hecho atractivo en problemas de control, particularmente para sistemas dinámicos no-lineales [22].

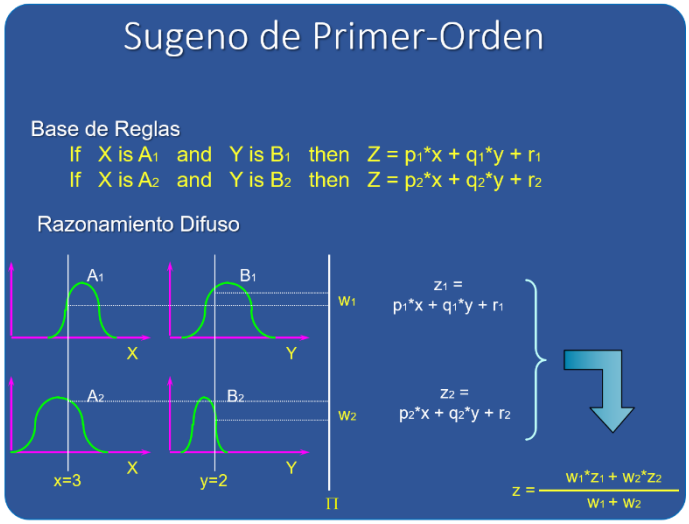

Figura 5. "*Defuzzificación*" Tipo Sugeno

El flujo de ejecución del proceso de autolocalización del agente procede de la manera ilustrada en la Figura 6:

Figura 6. Procedimiento de Autolocalización

La etapa de inicialización pone al sistema en total desconocimiento al agente respecto de su ubicación, i.e. $U_0 = \emptyset$. Una vez realizadas las mediciones odométricas sobre la posición (x, y, θ), se predice la nueva ubicación U_t^* en términos de la ubicación anterior. Esta nueva posible ubicación es contrastada con las observaciones actuales arrojadas por los sensores difusos, y se actualiza la creencia del agente acerca de su ubicación aproximada. Con base en ésto, se *defuzzifica* la posición para obtener la posición actual (x, y, θ), y se genera la acción de control correspondiente. Para un agente simple, este proceso se mantiene hasta que una acción externa lo termine. En un agente dirigido por objetivos, el proceso se continuaría hasta alcanzar el objetivo planteado.

3. CONCLUSIONES Y TRABAJO FUTURO

Se ha mostrado el diseño de un método de autolocalización para agentes físicos móviles basado en lógica difusa. La idea clave es la adaptación del esquema clásico de predicción-observación-actualización a la estructura convencional de un sistema difuso. La ventaja del método propuesto proviene del uso de la lógica difusa para la estimación de la ubicación incierta del agente en su entorno y el empleo de pericia heurística en la solución.

El trabajo futuro consiste en implementar el sistema en un robot comercial y evaluar su desempeño en distintos entornos acotados y no-acotados.

4. REFERENCIAS Y BIBLIOGRAFIA

[1] Russell, Stuart J.; Norvig, Peter (2010), Artificial Intelligence: A Modern Approach (3rd ed.), Upper Saddle River, New Jersey: Prentice Hall, ISBN-13: 978-0-13-604259-4.

[2] Kasabov, Nikola; Introduction: Hybrid intelligent adaptive systems, International Journal of Intelligent Systems, Vol.6, (1998) 453–454.

[3] Weiss, Gerhard, Multiagent systems (2nd ed.), Cambridge, MA: The MIT Press, (2013).

[4] A. Saffiotti, The uses of fuzzy logic in autonomous robot navigation, Soft Computing 1 (4) (1997) 180–197.

[5] K. Tanaka, M. Sugeno, Stability analysis and design of fuzzy control systems, Fuzzy Sets and Systems 45 (2) (1992) 135–156.

[6] K. Tanaka, M. Sano, Trajectory stabilization of a model car via fuzzy control, Fuzzy Sets and Systems 70 (2–3) (1995) 155–170.

[7] R.R. Yager, On a hierarchical structure for fuzzy modeling and control, IEEE Transactions on Systems, Man, and Cybernetics 23 (4) (1993) 1189–1197.

[8] A. Bonarini, M. Matteucci, M. Restelli, Concepts and fuzzy models for behavior-based robotics, International Journal of Approximate Reasoning 41 (2) (2006) 110–127.

[9] H. Liu, G.M. Coghill, D.J. Brown, Qualitative kinematics of planar robots: intelligent connection, International Journal of Approximate Reasoning 46 (3) (2007) 525–541.

[10] H. Liu, G.M. Coghill, D.P. Barnes, Fuzzy qualitative trigonometry, International Journal of Approximate Reasoning 51 (1) (2009) 71–88.

[11] I. Bloch, Information combination operator for data fusion: a compartive review with classification, IEEE Transactions on Systems, Man, and Cybernetics, Part A 26 (1) (1996) 52–67.

[12] S. Benferha, C. Sossai, Reasoning with multiple-source information in a possibilistic logic framework, Information Fusion 7 (1) (2006) 80–96.

[13] W. Burgard, D. Fox, D. Henning, T. Schmidt, Estimating the absolute position of a mobile robot using position probability grids, in: 13th National Conference on Artificial Intelligence, Menlo Park, AAAI, AAAI Press/MIT Press, 1996, pp. 896–901.

[14] J.E. Hopcroft, R. Motwani, and J. Ullman; Introduction to Automata Theory, Languages, and Computation (3rd Edition), ISBN-13: 978-0321455369, 2006.

[15] Edward R. Dougherty, An Introduction to Morphological Image Processing, ISBN 0-8194-0845-X (1992).

[16] Jinsung Oh, Structuring Element Representation of an Image and Its Applications, International Journal of Control, Automation, and Systems, vol. 2, no. 4, pp. 509-515, December 2004.

[17] Bloch, I., Maıtre, H.: Fuzzy Mathematical Morphologies: A Comparative Study., Pattern Recognition 28 (1995) 1341–1387.

[18] Thrun, S., Burgard, W., Fox, D., Probabilistic Robotics, MIT Press, ISBN: 9780262201629, 2005.

[19] J. Vanicek, I. Vrana, S. Aly, Fuzzy aggregation and averaging for group decision making: A generalization and survey, Knowledge-Based Systems 22 (2009) 79–84.

[20] George J. Klir, Bo Yuan, Fuzzy Sets and Fuzzy Logic: Theory and Applications, Prentice Hall; 1st edition (1995), ISBN-13: 978-0131011717

[21] T. Dean, K. Kanasawa, J. Shewchuk, Prediction, Observation, and Estimation in Planning and Control, 5th IEEE International Symposium on Intelligent Control, 1990, Philadelphia, PA, USA.

[22] T. Takagi, M. Sugeno, Fuzzy Identification of Systems and Its Applications to Modeling and Control, IEEE Transactions on Systems, Man and Cybernetics, 1 (1985) 116-132.