

ALGORITMO DIFUSO ADAPTABLE PARA PREDICCIÓN DE TRAYECTORIA BLANCO MÓVIL EN SISTEMAS DE CONTROL DE TIRO

Francisco Gil Navia¹, Juan Contreras Montes²

negrogil@hotmail.com, epcontrerasjeee.org

Escuela Naval de Cadetes Almirante Padilla, Cartagena, Colombia

RESUMEN

El problema de control de tiro implica mucho más que lograr que el cañón se apunte correctamente sobre el blanco. Para lograr el objetivo se hace necesario hacer correcciones de apuntamiento teniendo en cuenta aspectos como el tiempo de vuelo del proyectil y la trayectoria y posición futura del blanco, lo que obliga a contar con sistemas de predicción. En este artículo se presenta un sistema automático de seguimiento de blanco aplicado en un prototipo de cañón. Se presenta un algoritmo de control predictivo difuso para el seguimiento y anticipación de la posición del objetivo, el cual puede ajustar automáticamente los parámetros del modelo de predicción de acuerdo a la dinámica del blanco móvil.

PALABRAS CLAVES

Identificación difusa, modelo predictivo difuso, seguimiento.

1. Introducción

Los proyectiles de fuego directo son disparados línea-de-vista apuntando desde plataformas en tierra, helicópteros, aviones y/o buques. Varios factores pueden causar fallas para alcanzar un objetivo [1], como las inexactitudes industriales del arma, las condiciones atmosféricas, el movimiento de la plataforma de disparo, entre otros. Cuando se trata de un blanco móvil, otro

¹ Oficial Naval, Ingeniero Naval Especialidad Electrónica, Escuela Naval Almirante Padilla, Cartagena, Colombia, negrogil@hotmail.com

² Doctor en Ciencias Técnicas, Docente Investigador Escuela Naval Almirante Padilla, Cartagena, Colombia, epcontrerasj@ieeee.org

Apoyos y Subvenciones: Escuela Naval Almirante Padilla – Facultad de Ingeniería Naval

problema afecta la efectividad del disparo y se debe al error en la predicción de la futura posición del blanco.

Diferentes estudios se han realizado para identificar las contribuciones de los movimientos de las manos y de los ojos en la predicción de la trayectoria de objetos móviles [2] que permiten detectar las fortalezas y debilidades del operador humano en el enganche de un blanco móvil, inclusive cuando el objetivo deja de ser percibido por los ojos. Para contrarrestar la falla humana, ha despertado gran interés la investigación en el desarrollo de algoritmos de predicción [3], [4], especialmente mediante la generación de sistemas difusos predictivos a partir de datos experimentales de entrada y salida.

Una de las primeras propuestas para diseñar automáticamente un sistema difuso a partir de datos, fue el esquema de búsqueda en tablas [5]. Después Sugeno y Yasukawa [6] propusieron un método para identificar los parámetros de modelos difusos usando consecuentes tipo impulso unitario, sin embargo este método requería muchas reglas y presentaba poca capacidad de descripción.

La identificación difusa se ha usado antes para obtener modelos predictivos a partir de datos de entrada y salida experimentales. Varios investigadores [7],[8] han trabajado referencias clásicas, como el horno de gas de Box-Jenkins y las series caóticas de tiempo de Mackey-Glass, obteniendo modelos predictivos con buena exactitud pero con poca interpretabilidad.

En [9], se propone una comparación del modelo de Grey [10] y un modelo de sistema predictivo difuso para series de tiempos, obteniendo buena exactitud pero la estructura del modelo predictivo difuso no se muestra.

En [11] se muestra un esquema de seguimiento de blancos, en tiempo real, para un robot autónomo. En este caso el controlador difuso es construido a mano.

La figura 1 muestra un esquema de seguimiento de blancos difuso. En este documento se propone un predictor difuso interpretable capaz de hacer seguimiento de la posición futura de blancos en avanzada. Una señal de video proveniente de una cámara web, es procesada para

obtener las coordenadas de un blanco $y(k)$. Un predictor difuso es usado para determinar la posición futura del blanco $y(k+1)$ usando tiempos pasados.

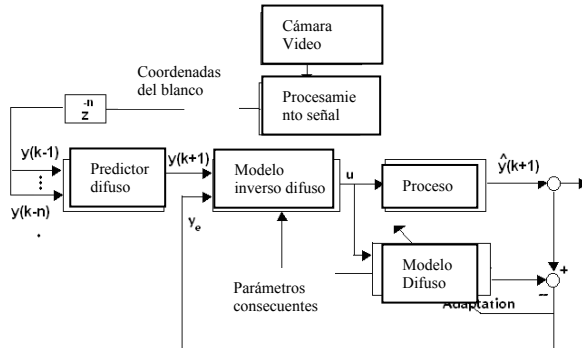


Figura 1. Predictor y controlador difuso para seguimiento de blancos

2. Identificación Difusa

Una regla difusa: “si u es A , entonces y es B ”, donde u y y representan dos variables numéricas, además $A \subset U$ y $B \subset Y$, forman pares entrada-salida difusos respectivamente definidos en los universos U y Y , esto es equivalente a la ecuación:

$$u_A(u) \leq u_B(y) \quad (1)$$

El error de inferencia ε , [12] está dado por

$$\varepsilon \approx \begin{cases} 0 & \dots & u_A(u) \leq u_B(y) \\ u_A(u) - u_B(y) & \dots & u_A(u) > u_B(y) \end{cases} \quad (2)$$

Una regla difusa de tipo “si u es A , entonces y es B ” con error de inferencia nulo, debe cumplir con la condición

$$u_A(u) = u_B(y) \quad (3)$$

Si el sistema tiene n entradas, debe ser representado por reglas de tipo “si u_1 es A_1 y u_2 es A_2 y ... y u_m es A_m , entonces y es B ”, y el sistema generado deben cumplir la condición

$$((u_{A_1}(x_k) \wedge u_{A_2}(x_k) \wedge \dots \wedge u_{A_m}(x_k)) = u_B(y_k) \quad (4)$$

donde \wedge representa una t-norma, o un operador de agregación, de lógica difusa.

A) Estructura de Modelo Difuso

Función de pertenencia

La partición del universo de la variable de entrada en el proceso de aprendizaje se hará con conjuntos triangulares normalizados, que se superponen en 0.5. La función de pertenencia triangular permite la reconstrucción del valor lingüístico en el mismo valor numérico después de emplear un método de defusificación [9]; además la superposición en 0.5 asegura que los apoyos de los conjuntos difusos son diferentes. Los conjuntos difusos generados por la variable de salida serán impulsos unitarios.

Distribución de la Función de Pertenencia

Las funciones triangulares difusas de cada variable de entrada se distribuirán de manera simétrica en el respectivo universo de entrada.

Operadores

Para combinar los operadores, se usaran operadores tipo OWA[13]

Método de inferencia

$$f(x^{(i)}) = \frac{\sum_{j=1}^L \bar{y}^j m_j(x^{(i)})}{\sum_{j=1}^L m_j(x^{(i)})} \quad (5)$$

Donde,

$$m_j(x^{(i)}) = u_{A_1^j}(x_1^{(i)}) \cdot u_{A_2^j}(x_2^{(i)}) \cdot \dots \cdot u_{A_n^j}(x_n^{(i)}) \quad (6)$$

es el grado de salida de la regla j -ésima de un sistema difuso tipo Sugeno, \bar{y}^j es el valor impulso correspondiente a la regla j . [14]

B) Algoritmo de Identificación Difusa

Dada una colección de datos experimentales de entrada y salida $\{x_k, y_k\}$, $k=1, \dots, N$, donde x_k es la matriz de datos de entrada n -dimensional $x_k^1, x_k^2, \dots, x_k^n$ y y_k es la matriz de salida unidimensional, el algoritmo se define en los siguientes pasos [11]:

- 1 Organización de los N pares de datos de entrada y salida $\{(x_i, y_i) \mid i=1,2,\dots,N\}$, donde $x_i \in \mathfrak{R}^n$ son vectores de entrada y y_i son escalares de salida
- 2 Determinación del rango del universo de entrada para cada variable, acuerdo a los valores máximos y mínimos $[x_i^-, x_i^+]$, $[y^-, y^+]$.

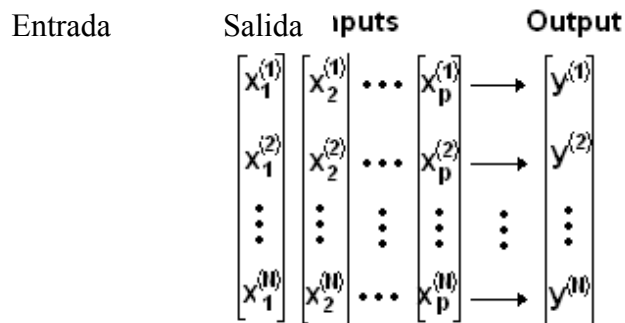


Figura 2. Organización de Datos

- 3 Distribución de las funciones triangulares sobre cada universo de entrada. Como norma general los vértices donde la función de pertenencia vale uno, (valor modal) están en el medio de la región cubierta por la función de pertenencia, mientras que los otros dos vértices con valor cero, caen en la mitad de las dos funciones aledañas.
- 4 Calcular la posición de los valores modales a partir de las variables de entrada , acuerdo a

$$\begin{aligned}
 &\text{Si } u_{A_k^{(n)}}(x_k^{(i)}) = 1 \\
 & \quad y_s^{(n)} = y[i] \\
 &\text{fin,}
 \end{aligned}
 \tag{7}$$

donde $y_s^{(n)}$ corresponde a la proyección sobre el espacio de salida de los datos de entrada $x^{(i)}$, evaluando de la k -ésima variable de entrada en la n -ésima función de la partición correspondiente. El valor de salida correspondiente a esta proyección está dado por la i -ésima posición del vector de salida y .

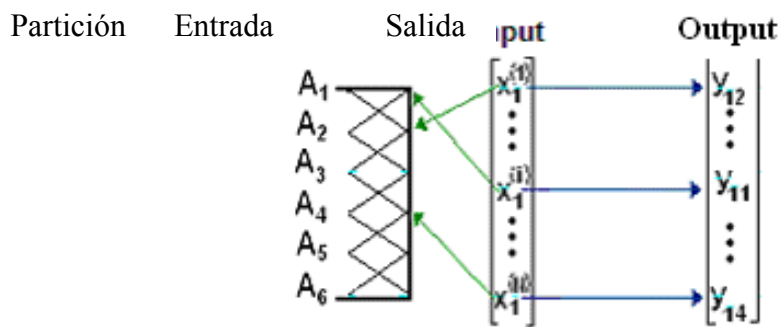


Figura 3. Generando Consecuentes

- 5 Determinación de reglas. Inicialmente el número de reglas son iguales al número de funciones de cada variable de entrada multiplicado por el numero de variables; en otras palabras, $n \times k$. Las funciones de pertenencia asociadas a un consecuente serán el antecedente de esta regla. Los antecedentes de aquellas reglas que tengan los mismos

consecuentes se funden usando el operador OWA, reduciendo de esta forma el numero de reglas. Un método adicional de reducir el número de reglas se presenta en [3].

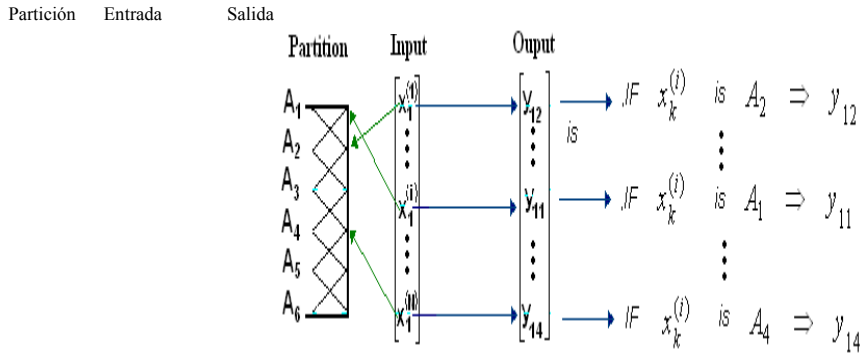


Figura 4. Generando reglas

- 6 Validación del modelo usando el método de inferencia descrito por (5)
- 7 Ajuste de parámetros, reubicando las funciones impulso de salida usando el método de mínimos cuadrados. La ecuación (5) se puede expresar de la forma:

$$f(x^{(i)}) = \sum_{j=1}^L y^j w_j(x^{(i)}) \quad (8)$$

Donde

$$w_j(x^{(i)}) = \frac{m_j(x^{(i)})}{\sum_{j=1}^L m_j(x^{(i)})} = w_j^i \quad (9)$$

Los valores de salida se pueden representar como $Y = W\theta + E$, que en la forma matricial esta dado por

$$\begin{bmatrix} y^1 \\ y^2 \\ \vdots \\ y^L \end{bmatrix}_Y = \begin{bmatrix} w_1^1 & w_2^1 & \dots & w_L^1 \\ w_1^2 & w_2^2 & \dots & w_L^2 \\ \vdots & \vdots & \ddots & \vdots \\ w_1^n & w_2^n & \dots & w_L^n \end{bmatrix}_W \begin{bmatrix} \theta^1 \\ \theta^2 \\ \vdots \\ \theta^L \end{bmatrix}_\theta + \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{bmatrix}_E \quad (10)$$

Figura 5. Datos de entrenamiento del modelo predictivo difuso

Un modelo predictivo difuso se obtuvo usando dos variables de entrada $\{y(k-1); y(k-3)\}$ para predecir $y(k+1)$. Se logró un error medio cuadrático (MSE) de 0.0020. La figura 6 muestra el modelo predictivo difuso obtenido y la figura 7 muestra la regla base.




Figura 6. Modelo predictivo difuso

Regla Base:

Si $y(k-1)$ es S y $y(k-3)$ es S,
entonces θ es S

Si $y(k-1)$ es H y $y(k-3)$ es H,
entonces θ es H

Figura 7. Regla base para el modelo predictivo difuso




Figura 8. Proceso de entrenamiento con datos reales (continuo) y predicción obtenida (punteado)

Después del proceso de entrenamiento nuevos datos son introducidos para validar el modelo predictivo difuso. Con los datos mostrados en la figura 9 un MSE de 0.0016 es obtenido. Con los datos mostrados en la figura 10 se obtiene un MSE de 0.0079.




Figura 9. Proceso de validación con datos reales (continuo) y predicción obtenida (punteado)




Figura 10. Proceso de validación con datos reales (continuo) y predicción obtenida (punteado)

4. Conclusión

Un método para obtener modelos predictivos, difusos e interpretables, basado en minimización de error de inferencia fue presentado, generando particiones suma-1 de los antecedentes a partir de funciones triangulares con particiones suma-1 asumidas inicialmente, evitando las sobre posiciones complejas que se presentan con otros métodos.

La aplicación real de la aproximación propuesta se demuestra en el proceso de seguimiento de un blanco en movimiento.

Referencias

- [1] Ollerenshaw, D., Costello, M., "Model Predictive Control of a Direct Fire Projectile Equipped with Canards", AIAA Atmospheric Flight Mechanics Conference and Exhibit, 15 - 18 August 2005, San Francisco, California
- [2] Wexler, M., Klam, F., "Movement prediction and movement production", Journal of Experimental Psychology: Human Perception and Performance, vol. 27, No. 1, pp. 48-64, 2001
- [3] Liu, P.X. Meng, M.Q.-H., "Online data-driven fuzzy clustering with applications to real-time robotic tracking", IEEE Trans. Fuzzy Systems, vol. 12, No. 4, pp. 516 – 523, Aug. 2004.

- [4] Contreras, J, “Generating Dynamic Fuzzy Models for Prediction Problems”. 28th North American Fuzzy Information Processing Society Annual Conference, Cincinnati, Ohio, USA. Jun. 2009.
- [5] Wang, L-X, Mendel, J.M., “Generating fuzzy rules by learning from examples”, IEEE Transactions, Nov. 1992.
- [6] Sugeno, M., Yasukawa, T., “A fuzzy logic based approach to qualitative modeling”. Transactions on Fuzzy Systems, vol. 1, No. 1, pp. 7-31. 1993
- [7] Gaweda, A.E., and Zurada, J.M. “Data-Driven Linguistic Modeling Using Relational Fuzzy Rules”, IEEE Trans. Fuzzy Systems, vol. 11, No. 1, pp.121-134, 2003
- [8] Nauck, D., Kruse, R., “Neuro-fuzzy systems for function approximation”. Fuzzy Sets and System. 101(2), pp. 261-271. Jan. 1999.
- [9] Dounis, A. I., Tiropanis, P., Tseles, D., Nikolaou, G. and Syrcos, G. P.” A Comparison of Grey Model and Fuzzy Predictive Model for Time Series”. International Journal of Computational Intelligence Volume 2 Number 3. pp 176-182. 2006
- [10] Li, T-H. S., Chang, S-J., and Tong, W., “Fuzzy Target Tracking Control of Autonomous Mobile Robots by Using Infrared Sensors”, IEEE Trans. Fuzzy Systems, vol. 12, No. 4, pp.491-501, 2004
- [11] Contreras, J., Misa, R., Murillo, L., “Interpretable Fuzzy Models from Data and Adaptive Fuzzy Control: A New Approach”. IEEE International Conference on Fuzzy Systems. IEEE Computational Intelligence Society. Pags.: 1591-1596. 2007
- [12] Sala, A., Validación y Aproximación Funcional en Sistemas de Control Basados en Lógica Borrosa. Universidad Politécnica de Valencia. PhD Thesis. 1998.
- [13] Babuska, R. Fuzzy and Neural Control. Disc Course Lecture Notes. Delft University of Technology. Delft, the Netherlands. 2001.
- [14] Passino, K, y Yurkovich, S. Fuzzy Control. Addison-Wesley. California. 1998