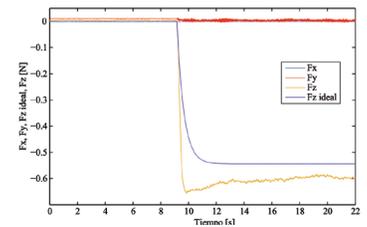


# Identificación de parámetros con neuronas difusas: aplicación a drones y motores de inducción



## Parameter identification using fuzzy neurons: application to drones and induction motors



Abigail-María-Elena Ramírez-Mendoza<sup>1</sup>, José-Roberto Covarrubias-Fabela<sup>1</sup>, Luis-Antonio Amezcua-Brooks<sup>1</sup> y Diana Hernández-Alcántara<sup>3</sup>

<sup>1</sup> Universidad Autónoma de Nuevo León (UANL). Facultad de Ingeniería Mecánica y Eléctrica (FIME). Centro de Investigación e Innovación en Ingeniería Aeronáutica (CIIIA). Carretera a Salinas Victoria Km.2.3. - 66600 Apodaca, Nuevo León (México).

<sup>2</sup> Universidad de Monterrey. Dpto. de Física y Matemáticas. Av. Ignacio Morones Prieto 4500 Pte. - 66238 San Pedro Garza García, Nueva León (México).

DOI: <http://dx.doi.org/10.6036/8439> | Recibido: 11/05/2017 • Evaluado: 12/05/2017 • Aceptado: 22/11/2017

### ABSTRACT

- Recently the use of unmanned aerial vehicles (UAV) has been extended in diverse applications. Within the most predominant configurations are rotary wing vehicles with multiple rotors. These vehicles normally present unstable dynamic behaviour in open loop, and therefore it is necessary to implement appropriate control systems. One of the most important requirements for the design of such control systems is the aerodynamic model of the multi-rotor propulsion system. On the other hand, parametric identification is widely used in the industrial context, such as control of electric machines. In particular for the case of induction motors, the knowledge of the model parameters is essential to tune the controllers properly. Among the most successful identification algorithms in recent applications are those based on neural networks. Within this context, an innovative type of neuronal networks based on adaptive fuzzy spiking neurons (AFSNs) has captured the attention of the community due to its fuzzy neuronal characteristics for unipolar and bipolar signals, such as its fuzzy learning algorithm, a sigmoidal activation function, refractory period, axonal delay, and spikes generation. This article explores for the first time the possibility of using AFSNs for the identification of the multi-rotor UAV propulsion subsystem and the parameters of the electric subsystem of an induction motor. The results show that AFSNs are capable of identifying both systems with a high degree of precision. This opens up the possibility of using AFSNs in both, experimental aerodynamics applications for UAVs and industrial control applications.
- **Keywords:** parameter identification, adaptive fuzzy spiking neurons, UAV, induction motor.

### RESUMEN

Recientemente la utilización de vehículos aéreos no tripulados (VANT) con múltiples rotores se ha extendido en diversas aplicaciones. La mayoría de estos vehículos presentan un comportamiento dinámico inestable en lazo abierto y, por lo tanto, es necesario implementar sistemas de control apropiados. Uno de los requerimientos más importantes para realizar el diseño de dichos sistemas de control es el modelo aerodinámico del sistema de propulsión con múltiples rotores. Por otro lado, la identificación paramétrica también es utilizada en contextos industriales tales como el control de máquinas eléctricas. En particular, en el caso de los motores de inducción el conocimiento de los parámetros es un requisito imprescindible para ajustar apropiadamente los controladores de los mismos. Dentro de los algoritmos de iden-

tificación con más éxito en recientes aplicaciones se encuentran aquellos basados en redes neuronales. Dentro de este contexto, un tipo innovador de redes neuronales basado en neuronas generadoras de espigas difusas adaptativas (NGEDA) ha captado la atención de la comunidad debido a sus características neuronales difusas para señales unipolares y bipolares, como es su algoritmo de aprendizaje difuso, una función de activación tipo sigmoideal, periodo refractario, retardo axónico y generación de espigas. En este artículo se explora, por primera vez, la posibilidad de utilizar NGEDA para la identificación del subsistema de propulsión del VANT con múltiples rotores y de los parámetros del subsistema eléctrico de un motor de inducción. Los resultados muestran que las NGEDA son capaces de identificar ambos sistemas con un alto grado de precisión. Esto abre la posibilidad de utilizar NGEDA tanto en aplicaciones de aerodinámica experimental para VANT como en aplicaciones de control industrial.

**Palabras clave:** neuronas generadoras de espigas difusas adaptativas, identificación paramétrica, vehículo aéreo no tripulado, motor de inducción.

### 1. INTRODUCCIÓN

El uso de vehículos aéreos no tripulados (VANT) de ala rotativa con múltiples rotores en diversos sectores de la sociedad ha atraído la atención de la comunidad científica y tecnológica. Una de las desventajas que limita el uso extendido de estos vehículos es que son inherentemente inestables en lazo abierto. Es decir, requieren forzosamente de sistemas de control retroalimentado a bordo de la aeronave para operar. Dentro de los sistemas de control utilizados para estos vehículos se pueden encontrar dos grandes clasificaciones: 1) control basado en modelo y 2) control basado en datos. La primera opción normalmente tiene menor costo computacional y puede implementarse fácilmente. Una desventaja es la dependencia en el conocimiento de modelos precisos. En contraste, los sistemas de control basados en datos prácticamente no requieren conocimiento previo del sistema, pero tienen mayores requerimientos de procesamiento computacional.

Dentro del contexto de control de VANT muchas veces se ha optado por sistemas de control basados en modelo [1-3], debido a que estos vehículos no cuentan con una gran capacidad de cómputo. Esto permite argumentar que en la actualidad el éxito en el diseño de sistemas de control para VANT multi-rotor depende en gran medida de los modelos con los que se cuentan para realizar el diseño de los controladores. Existen dos elementos que confor-

man el modelo de los VANT multi-rotor: 1) dinámicas de cuerpo rígido y 2) modelo aerodinámico del sistema de propulsión [4-9]. Para el primer elemento (cuerpo rígido) los parámetros relevantes consisten en dimensiones y masas inerciales que pueden ser medidas con métodos de caracterización mecánicos bien conocidos. En el caso del subsistema de propulsión la existencia de múltiples-rotos introduce fenómenos de interacción que no se presentan con un solo rotor. Aunque se conocen bien las dinámicas motor-hélice, los fenómenos aerodinámicos introducen un gran nivel de incertidumbre. En este sentido una propuesta que ha tenido éxito es tratar de integrar todos los fenómenos en un modelo simplificado que posteriormente se ajuste experimentalmente [10]. Para este propósito es común que se empleen bancos de prueba para la caracterización de los VANT [10-12, 13].

En el caso de aplicaciones industriales, el control de motores de inducción se ha convertido en un aspecto primordial dentro de los sistemas automatizados. Es bien sabido que para lograr altos niveles de desempeño en el control de motores de inducción es necesario conocer los parámetros del subsistema eléctrico de la máquina [14, 15]. En particular los parámetros asociados con la dinámica de flujo del rotor son difíciles de identificar ya que no es fácil medir esta variable.

Existen métodos que permiten estimar los parámetros eléctricos sin necesitar mediciones del flujo. La mayoría de los métodos que se basan en mediciones de las variables eléctricas del estator requieren tanto mediciones de corriente como de voltaje [16-17]. Sin embargo, las mediciones de voltajes no son requeridas para la operación de los esquemas típicos de alto desempeño, como el control vectorial orientado al flujo del rotor. En este sentido, un esquema de estimación de los parámetros eléctricos que utilice sólo las mediciones de las corrientes tiene ventajas.

En este artículo se propone utilizar un novedoso algoritmo de identificación para obtener modelos paramétricos de los elementos de propulsión de los VANT y del subsistema eléctrico de los motores de inducción. Los métodos de identificación basados en redes neuronales han mostrado ser útiles en sistemas con un alto grado de complejidad; no obstante, en la mayoría de los casos los algoritmos propuestos no generan identificaciones paramétricas [18-21]. Por otro lado, las redes neuronales han mostrado también ser eficaces en diversas aplicaciones [22, 23]. En tiempos recientes la aparición de redes neuronales basados en neuronas generadoras de espigas difusas adaptativas (NGEDA) ha captado la atención de la comunidad debido a sus características [24-29].

Debido a su reciente aparición las NGEDA no se han probado experimentalmente en aplicaciones de identificación paramétrica. Los resultados muestran que el algoritmo propuesto basado en NGEDA es capaz de alcanzar un muy bajo nivel de error. La diversidad de las aplicaciones presentadas permite afirmar que el desarrollo presentado aquí se podría adaptar a otros problemas de identificación.

## 2. DESCRIPCIÓN DEL SUBSISTEMA DEL VANT DRON, EL SISTEMA DE PROPULSIÓN

Las principales variables a medir en pruebas aerodinámicas experimentales para los VANT son la fuerza de empuje, el peso, el arrastre y los momentos de cabeceo, alabeo y guiñada. Se definen el eje lateral o transversal (eje  $y$ ) el movimiento de cabeceo; el eje longitudinal (eje  $x$ ) para la fuerza de arrastre y el movimiento de alabeo, y también el eje vertical (eje  $z$ ) para la fuerza de empuje, peso y el movimiento de guiñada.

Para obtener los parámetros de los modelos matemáticos de

sistemas dinámicos como los VANT de ala rotativa [1-4] se pueden utilizar métodos de identificación paramétricos [30, 31]. En este caso se propone el procesamiento con Redes Neuronales Artificiales (RNA) y algoritmos de entrenamiento para optimización de los pesos de la RNA para obtener una aproximación en la construcción de los modelos matemáticos. Estos algoritmos se explican a fondo en [24-29]; un breve resumen se incluye en el *material suplementario* de este artículo para complementar su lectura.

El banco de prueba, presentado por primera vez en [10], se muestra en la Fig. (1). Consta de cuatro motores con hélice operados con modulación por ancho de pulso (MAP), sistema de adquisición de datos y sistema de medición de fuerzas y momentos en cada eje.

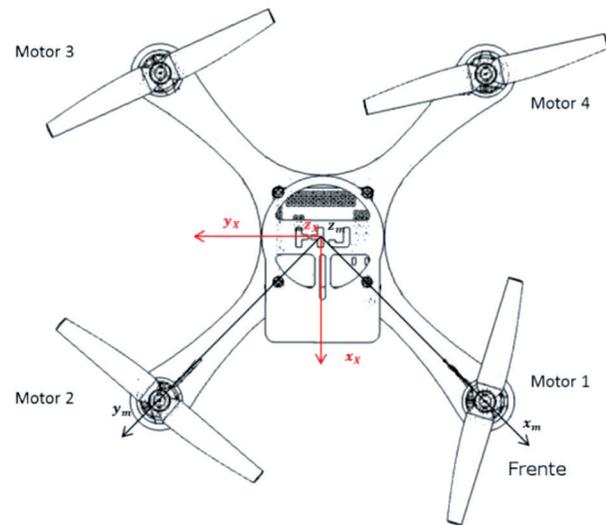


Fig. 1: VANT dron

El modelo matemático propuesto en [10, 32-34] considera que el total de fuerzas y momentos inducidos por el sistema de propulsión se produce de acuerdo con la Ec. (1):

$$\begin{bmatrix} F_z \\ M_p \\ M_q \\ M_r \end{bmatrix} = \begin{bmatrix} -k_f & -k_f & -k_f & -k_f \\ 0 & -k_{tp} & 0 & k_{tp} \\ k_{tq} & 0 & -k_{tq} & 0 \\ -k_m & k_m & -k_m & k_m \end{bmatrix} \begin{bmatrix} U_1^2 \\ U_2^2 \\ U_3^2 \\ U_4^2 \end{bmatrix} = P \begin{bmatrix} U_1^2 \\ U_2^2 \\ U_3^2 \\ U_4^2 \end{bmatrix} \quad (1)$$

donde  $F_z$  es la fuerza de empuje en el eje  $z$ ,  $M_p$ ,  $M_q$ ,  $M_r$  son los momentos con respecto a los ejes  $x$ ,  $y$ ,  $z$ , las ganancias  $K_p$ ,  $K_q$ ,  $K_m$  son los parámetros a identificar y  $U_i \in [0,1]$  es el índice de modulación de la señal MAP con  $i=1,2,3,4$ .

Utilizando el banco de pruebas se obtuvieron datos con frecuencia de muestreo de 20 kHz. Las fuerzas y momentos se filtraron con un filtro paso-bajas de segundo orden con frecuencia de corte de 30 Hz. Los análisis de vibraciones presentados en [10], confirman que este tipo de filtro permite eliminar las componentes de vibración del banco de pruebas y de las hélices, preservando la principal información del proceso.

La fuerza de empuje se define en la Ec. (2) [35]:

$$F_z = \frac{1}{2} \cdot \rho \cdot S_T \cdot C_T \cdot (k_v \cdot U_i)^2 \quad (2)$$

donde  $\rho$  es la densidad del aire,  $S_T$  es el área de barrido de la hélice,  $C_T$  es el coeficiente de empuje y  $k_v$  es la velocidad angular de la hélice en rad/s.

Como se requiere conocer el valor de  $k_v$  y también el valor de la constante  $k_l = \frac{1}{2} \cdot \rho \cdot S_r \cdot C_r$  entonces se propone un valor fijo para  $k_l$  y mediante el algoritmo de aprendizaje de las *NGEDA* se calcula el vector de valores correspondientes a  $k_v$  teniendo como datos los vectores  $F_z$  y  $U_i$ . Por lo tanto,

$$F_{z \text{ modelo}} = k_l \cdot \sum_{i=1}^n (k_{v_i} \cdot U_i)^2 \quad (3)$$

De manera similar para los momentos:

$$M_{j \text{ modelo}} = -k_j \cdot \sum_{i=1}^n (k_{v_i} \cdot U_i)^2 \quad (4)$$

donde  $n = 4$  es el número de rotores,  $k_i$  y  $k_j$  son los parámetros a identificar y  $j$  puede ser  $p, q, r$ , correspondiente a los momentos en  $x, y, z$ .

Por lo tanto, el modelo matemático propuesto es:

$$\begin{bmatrix} F_{z \text{ modelo}} \\ M_{p \text{ modelo}} \\ M_{q \text{ modelo}} \\ M_{r \text{ modelo}} \end{bmatrix} = \begin{bmatrix} k_l & k_l & k_l & k_l \\ 0 & k_p & 0 & -k_p \\ -k_q & 0 & k_q & 0 \\ k_r & -k_r & k_r & -k_r \end{bmatrix} \begin{bmatrix} (k_{v1} \cdot U_1)^2 \\ (k_{v2} \cdot U_2)^2 \\ (k_{v3} \cdot U_3)^2 \\ (k_{v4} \cdot U_4)^2 \end{bmatrix} \quad (5)$$

### 3. APROXIMACIÓN DEL MODELO MATEMÁTICO DEL SISTEMA DE PROPULSIÓN DEL VANT DE ALA ROTATIVA CON NGEDA

Las *NGEDA* desarrolladas en [24–29] proporcionan un modelo matemático de una neurona artificial inspirada en el funcionamiento de las neuronas biológicas de espiguelo rápido, con base en la lógica difusa y la teoría de Gupta, con características neuronales difusas para señales unipolares y bipolares, un algoritmo de aprendizaje difuso, una función de activación tipo sigmoial, tiempo refractario, retardo axónico y generación de espigas. Más información respecto a este tipo de neuronas se anexa en el *material suplementario* del artículo.

En la Fig. (2a) se muestra el diagrama de bloques del sistema de propulsión. Para aproximar dicho sistema se propone utilizar una configuración con *NGEDA* Fig. (2b), la cual está conformada por una capa de entrada, una capa oculta y una capa de salida con 4, 4 y 4 neuronas respectivamente. La parametrización de la ecuación (5) a partir de la estructura con *NGEDA* de la Fig. (2b) se establece a continuación.

Considerando la ecuación (5), la fuerza del modelo de empuje

$F_{z \text{ modelo}}$  se puede expresar de la siguiente forma:

$$F_{z \text{ modelo}} = k_l \cdot [(w_{in3} \cdot f_v \cdot U_1)^2 + (w_{in6} \cdot f_v \cdot U_2)^2 + (w_{in9} \cdot f_v \cdot U_3)^2 + (w_{in12} \cdot f_v \cdot U_4)^2] \quad (6)$$

donde  $k_{v1} = w_{in3} \cdot f_v$ ,  $k_{v2} = w_{in6} \cdot f_v$ ,  $k_{v3} = w_{in9} \cdot f_v$  y  $k_{v4} = w_{in12} \cdot f_v$ . En este caso  $f_v$  es una constante que se utiliza para normalizar los términos  $(w_{in} \cdot f_v \cdot U)^2$  mientras que los parámetros a identificar son  $w_{in3}$ ,  $w_{in6}$ ,  $w_{in9}$  y  $w_{in12}$ . Finalmente, el parámetro  $k_l$  se utiliza para de-normalizar la fuerza acumulada  $F_{z \text{ modelo}}$ . De esta manera los parámetros a identificar de la ecuación (6) se establecen como los pesos de las *NGEDA* de la capa de salida; es decir, las neuronas 3, 6, 9 y 12 (ver Fig. 2b). Con esta parametrización es posible reconstruir los parámetros deseados al "entrenar" la red de la Fig. 2b.

De manera similar se parametrizan el resto de las variables de salida de la ecuación (5):

$$M_{p \text{ modelo}} = [0 + (k_{v2} \cdot U_2)^2 \cdot w_{in6} \cdot f_p + 0 - (k_{v4} \cdot U_4)^2 \cdot w_{in12} \cdot f_p] \quad (7)$$

$$M_{q \text{ modelo}} = [-(k_{v1} \cdot U_1)^2 \cdot w_{in3} \cdot f_q + 0 + (k_{v3} \cdot U_3)^2 \cdot w_{in9} \cdot f_q + 0] \quad (8)$$

$$M_{r \text{ modelo}} = \begin{bmatrix} (k_{v1} \cdot U_1)^2 \cdot w_{in3} \cdot f_r - (k_{v2} \cdot U_2)^2 \cdot w_{in6} \cdot f_r \\ + (k_{v3} \cdot U_3)^2 \cdot w_{in9} \cdot f_r - (k_{v4} \cdot U_4)^2 \cdot w_{in12} \cdot f_r \end{bmatrix} \quad (9)$$

donde los parámetros  $f_p$ ,  $f_q$  y  $f_r$  se utilizan para normalizar los términos individuales de las ecuaciones (7)–(9).

Es necesario normalizar cada uno de los términos de las ecuaciones (6)–(7) debido a las *NGEDA* se basan en lógica difusa bipolar, es decir, las señales de entrada y salida se encuentran en el intervalo  $[-1,1]$ . No obstante, esto no representa una limitación en la práctica si se tiene cuidado de mantener las señales en los intervalos asignados.

### 4. SIMULACIONES Y RESULTADOS

Utilizando un túnel de viento en condiciones controladas se obtuvieron mediciones experimentales de las variables de entrada y salida de la Fig. (2a) con una velocidad del aire de 0 m/s. En todos los casos se utilizó el siguiente conjunto de parámetros: valores iniciales de los pesos  $W_{ref_i} = 1$ , valores iniciales de los pesos de salida  $W_{in_i} = 0.1$ , valor inicial del factor de aprendizaje de cada neurona  $\gamma_i = 1$  y umbral para las neuronas  $V_{umbral_i} = -1$ . Los factores utilizados para normalizar las salidas de las neuronas fueron  $f_v = 1500$ ,  $f_p = 8.3333e-5$ ,  $f_q = 1.3e-5$  y  $f_r = 5.0e-7$ . De acuerdo con la parametrización presentada en las ecuaciones (6)–(9), se realizaron 5 iteraciones del algoritmo de aprendizaje con cada una de las salidas modeladas; es decir,  $F_{z \text{ modelo}}$ ,  $M_{p \text{ modelo}}$ ,  $M_{q \text{ modelo}}$  y  $M_{r \text{ modelo}}$ . Los pesos relevantes de la red se presentan en la Tabla 1.

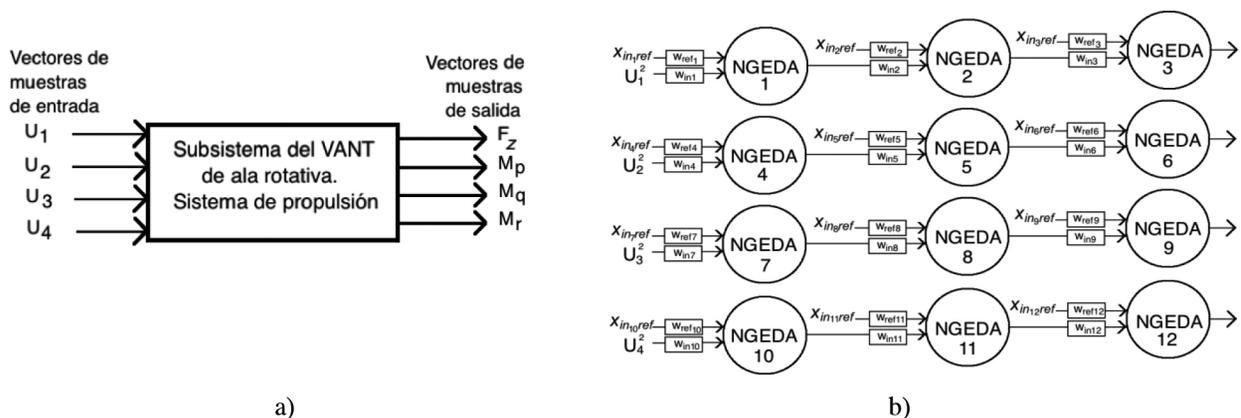


Fig. 2: Configuración con *NGEDA* para la identificación de parámetros de la aproximación del modelo matemático del Subsistema del VANT drone, el sistema de propulsión. Note que para esta arquitectura en todo caso  $x_{inNref} = 1$

Variable Pesos	$F_{z \text{ modelo}}$	$M_p \text{ modelo}$	$M_q \text{ modelo}$	$M_r \text{ modelo}$
$W_{in3}$	0.0625	0	0.1527	1.0
$W_{in6}$	0.0625	0.4042	0	1.0
$W_{in9}$	0.0625	0	0.1527	1.0
$W_{in12}$	0.0625	0.4042	0	1.0

Tabla 1. Pesos de la capa de salida después de realizar entrenamiento de la red neuronal para cada variable de salida

El tiempo de procesamiento promedio para una iteración del algoritmo es de 100ms en una computadora con procesador Core i5™. Las limitaciones computacionales de las computadoras actuales restringen la ejecución del algoritmo a aplicaciones fuera de línea. No obstante, el aumento en la capacidad computacional sugiere que en el futuro aplicaciones de tiempo real serían posibles.

A partir de los pesos para la variable  $F_{z \text{ modelo}}$  es posible notar que  $K_{v1} = K_{v2} = K_{v3} = K_{v4} = 93.7602$ . Estos parámetros se mantuvieron fijos para las ecuaciones (7)-(9) para que existiese coherencia entre todo el modelo. Utilizando los pesos para el resto de las variables  $M_p \text{ modelo}$ ,  $M_q \text{ modelo}$  y  $M_r \text{ modelo}$  se obtienen los siguientes parámetros de las ecuaciones (7)-(9):  $K_f = 6.7e -5$ ,  $K_p = 3.368e -5$ ,  $K_q = 1.9854e -6$  y  $K_r = 5.0e -7$ . Lo cual completa todos los parámetros de la ecuación (5). Finalmente, a partir de esta ecuación se pueden recuperar fácilmente todos los parámetros del modelo aerodinámico original de la ecuación (1). Los resultados se muestran en la Tabla 2.

Parámetros del modelo		Error de modelización	
		$e = F_z - F_{z \text{ modelo}}$	
$k_f$	0.5889	Valor medio	1.64e-2
$k_{t_p}$	0.2960	Varianza	4.8e-3
		Desviación estándar	6.93e-2
$k_{t_q}$	0.0174	Error cuadrático medio	5.1e-3
		Error absoluto medio	3e-2
$k_m$	0.0043	Error porcentual absoluto medio	3.93%

Tabla 2: Parámetros identificados equivalentes para la Ec. (1) y cuantificación del error de identificación para  $F_z$

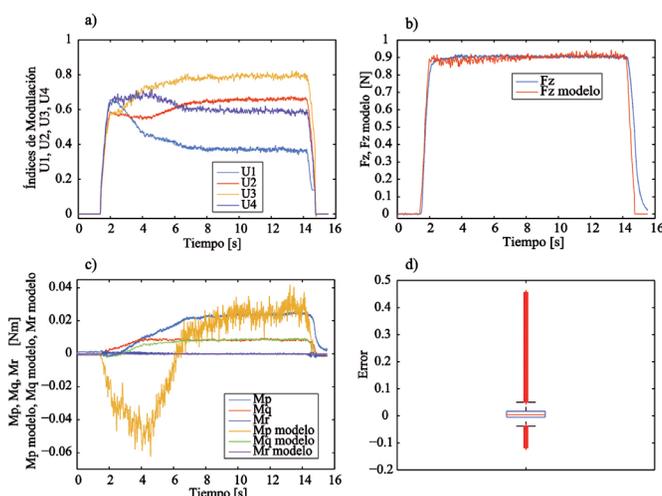


Fig. 3: (a) Índices de modulación de la MAP para la maniobra de empuje. (b) Fuerza de empuje medida y modelo, (c) Momentos y (d) Gráfico de caja del error de modelado

Para verificar la efectividad de la metodología se simuló la variable de salida más relevante para esta aplicación  $F_{z \text{ modelo}}$  considerando los parámetros de la Tabla 2 y las entradas experimentales mostradas en la Fig. (3a). La Fig. (3b) muestra una comparación entre la respuesta experimental y la obtenida a partir del modelo. En el caso de las variables secundarias para este tipo de aplicaciones, es decir los momentos  $M_p$ ,  $M_q$  y  $M_r$ , la Fig. (3c) presenta la comparación correspondiente. Finalmente, la Fig. (3d) muestra el gráfico de caja del error de modelado, el cual incluye la mediana del error, así como la distribución del mismo por cuartiles. Estas figuras confirman el bajo nivel de error que se puede alcanzar con el método propuesto. Así mismo, los parámetros de la Tabla 2 son similares a los que se reportan en [10], en donde se realiza un proceso de identificación similar utilizando métodos más tradicionales como mínimos cuadrados. Finalmente, en la Tabla 2 también se presentan algunas mediciones cuantitativas del error de modelado resultante para la variable principal  $F_z$ . Es importante mencionar que para el caso del *error porcentual absoluto medio* se utilizaron los datos de los tiempos entre 1.54s y 14.64s para evitar los datos cercanos a cero, evitando la indeterminación de este parámetro.

Por otro lado, se presenta una validación de dinámica inversa. Se propone utilizar el vector  $FM_{ref} = [F_z \ M_p \ M_q \ M_r]^T$  como entrada de referencia y calcular a partir de este los índices de modulación necesarios para obtener la fuerza y momentos deseados. Esto se logra calculado  $[U_1^2 \ U_2^2 \ U_3^2 \ U_4^2]^T = P^{-1} FM_{ref}$  donde  $P^{-1}$  es la inversa de la matriz de la ecuación (1). Una vez que se han calculado los índices de modulación estos se aplican experimentalmente y se verifica que las salidas medidas sean iguales a las deseadas. La Fig. (5) muestra la comparación entre la fuerza en el eje z deseada (ideal) y la medida experimentalmente. En este caso se desea que el resto de las fuerzas (en los ejes y y x) se mantengan en cero. Es importante mencionar que la validación de modelos basada en dinámica inversa suele resultar difícil ya que las respuestas pueden variar mucho debido a perturbaciones. No obstante, como se muestra en la Fig. (4) la fuerza de empuje  $F_z$  obtenida experimentalmente y la fuerza de empuje ideal  $F_{z \text{ ideal}}$  son muy similares.

### 5. IDENTIFICACIÓN DE LOS PARÁMETROS DEL SUBSISTEMA ELÉCTRICO DE UN MOTOR DE INDUCCIÓN

El control de motores de inducción de alto desempeño se ha convertido en una práctica estándar en la industria. Particularmente los esquemas de control vectorial orientados al flujo de rotor son los más utilizados en aplicaciones industriales [14, 15]. Sin embargo, para su correcto funcionamiento estos métodos requie-

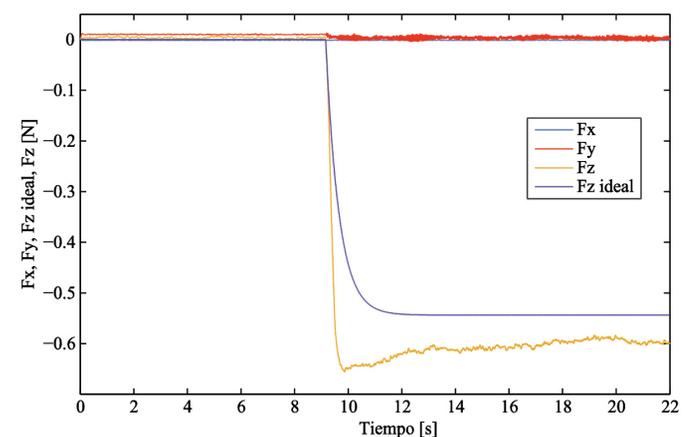


Fig. 4: Fuerza de empuje  $F_{z \text{ ideal}}$  y  $F_z$  adquiridas experimentalmente en un experimento de dinámica inversa utilizando el modelo identificado con NGEDA

ren del conocimiento de los parámetros del subsistema eléctrico de la máquina. Los parámetros del estator se utilizan para diseñar sistemas de control de las corrientes mientras que los parámetros del rotor se usan para ajustar los controladores vectoriales de flujo y torque. Uno de los parámetros que es particularmente difícil de identificar y que tiene un efecto mayor sobre el desempeño del sistema es la constante de tiempo del flujo de rotor. A continuación, se presenta la identificación paramétrica del subsistema eléctrico de un motor de inducción basado en datos experimentales utilizando una red de *NGEDA*.

El subsistema eléctrico de motor de inducción se puede modelar como sigue [14]:

$$\begin{bmatrix} \dot{I}_{as} \\ \dot{I}_{bs} \\ \dot{\psi}_{ar} \\ \dot{\psi}_{br} \end{bmatrix} = \begin{bmatrix} -a_1 & 0 & a_2 & \omega_r a_3 \\ 0 & -a_1 & -\omega_r a_3 & a_2 \\ a_4 & 0 & -a_5 & -\omega_r \\ 0 & a_4 & \omega_r & -a_5 \end{bmatrix} \begin{bmatrix} I_{as} \\ I_{bs} \\ \psi_{ar} \\ \psi_{br} \end{bmatrix} + \begin{bmatrix} b_1 & 0 \\ 0 & b_1 \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} V_1 \\ V_2 \end{bmatrix} \quad (10)$$

con:

$$a_1 = \frac{L_s^2 R_s + L_m^2 R_r}{\sigma L_s L_r^2}, \quad a_2 = \frac{L_m R_r}{\sigma L_s L_r^2}, \quad a_3 = \frac{L_m}{\sigma L_s L_r}, \quad a_4 = \frac{L_m R_r}{L_r}, \quad a_5 = \frac{R_r}{L_r}, \quad b_1 = \frac{1}{\sigma L_s}, \quad \sigma = 1 - \frac{L_m^2}{L_s L_r}$$

donde  $R_s$  y  $R_r$  son las resistencias del estator y del rotor respectivamente y  $L_s$ ,  $L_r$  y  $L_m$  son las inductancias del estator, del rotor y mutua respectivamente. Así mismo,  $I_{as}$  y  $I_{bs}$  son las corrientes del estator en coordenadas estacionarias,  $V_1$  y  $V_2$  son los voltajes del estator,  $\psi_{ar}$  y  $\psi_{br}$  son los flujos del rotor y  $\omega_r$  es la velocidad del rotor. En esta configuración la constante del tiempo del rotor está dada por  $1/a_5$ . Las entradas del sistema son los voltajes del estator ( $V_1$  y  $V_2$ ), que son considerados como conocidos, pero con moderada incertidumbre; mientras que las variables que se miden son las corrientes del estator ( $I_{as}$  e  $I_{bs}$ ) y la velocidad del rotor ( $\omega_r$ ).

Una de las principales dificultades en la identificación del sistema (10) es la dependencia con respecto a  $\omega_r$ , lo cual resulta en un modelo lineal variante en el tiempo o no lineal al considerar la dinámica del rotor. En [15] se muestra como diseñar controladores de alto desempeño a partir de los parámetros  $a_r$  de tal manera que son estos los que se desea identificar.

Con el propósito de realizar la identificación de parámetros con el método de las *NGEDA* se propone una red de *NGEDA* con cuatro capas, tres *NGEDA* en la primera capa (de entrada, neuronas 1 a 3), cuatro *NGEDA* en la segunda capa (oculta, neuronas 4 a 7), seis *NGEDA* en la tercera capa (oculta, neuronas 8 a 13) y seis *NGEDA* en la cuarta capa (de salida, neuronas 14 a 19). El proceso de parametrización para el modelo (10) se realiza de manera similar que para el ejemplo anterior. Resultando en una parametrización que utiliza los pesos de las neuronas de la capa de salida como se indica a continuación:  $a_1 = f_1 \cdot w_{in14,2}$ ,  $a_2 = f_2 \cdot w_{in15,2}$ ,  $a_3 = f_3 \cdot w_{in16,2}$ ,  $a_4 = f_4 \cdot w_{in17,2}$ ,  $a_5 = f_5 \cdot w_{in18,2}$ ,  $b_1 = f_6 \cdot w_{in19,2}$ . Donde las variables  $f_i$  se utilizan para escalar los productos  $f_i \cdot w_{in}$  al rango deseado.

### 5.1. SIMULACIONES Y RESULTADOS

Se realizaron mediciones experimentales de las corrientes del estator y de la velocidad del rotor durante un experimento de arranque simple de la máquina en un banco de pruebas conformado por:

- Motor de asíncrono de jaula de ardilla de dos polos.
- Inversor de dos niveles basado en *IGBT* con frecuencia de conmutación de 5kHz
- Tarjeta de captura de datos *DSPACE™* con frecuencia de muestreo de 50kHz

Para realizar la identificación de parámetros del modelo matemático del sistema (10) se propusieron los siguientes parámetros iniciales para la red:  $w_{refi} = -1$ ,  $x_{inNref} = 1$ ,  $w_{inNi} = 0.5$ ,  $\gamma_i = 0.1$  y  $V_{umbral} = -1$ . Las señales de entrada de la red son los voltajes  $V_1$  y  $V_2$  y la velocidad angular  $\omega_r$ . Nótese que  $V_1$  y  $V_2$  no se miden directamente, sino que se reconstruyen de los comandos del inversor, por lo cual estos contienen un grado moderado de incertidumbre.

Se realizaron 2 recursiones para el algoritmo de aprendizaje se propusieron los siguientes factores de escalamiento para las neuronas de la capa de salida:  $f_1 = 750$ ,  $f_2 = 270$ ,  $f_3 = 10$ ,  $f_4 = 50$ ,  $f_5 = 30$  y  $f_6 = 10$ . Los parámetros resultantes del proceso de identificación se muestran en la Tabla 3.

Parámetros del modelo		Error de modelización $e = I_{as} - I_{as\ modelo}$	
$a_1$	359.18		
$a_2$	139.36	Valor medio	2.6e-3
$a_3$	9.04	Varianza	9.1e-3
$a_4$	22.29	Desviación estándar	9.56e-2
$a_5$	15.41	Error cuadrático medio	9.1e-3
$b_1$	9.73	Error absoluto medio	6.67e-2

Tabla 3: Parámetros identificados para la Ec. (10) y cuantificación del error de identificación para  $I_{as}$

Se realizó una evaluación con las respuestas experimentales obtenidas considerando los voltajes de entrada mostrados en la Fig. (5a), que producen la respuesta en  $\omega_r$  mostrada. La Fig. (5b) presenta una comparación entre las respuestas experimentales de las corrientes del estator y las del modelo, mientras que la Fig. (5c) muestra un acercamiento. Finalmente, la Fig. (5d) muestra un gráfico de caja del error de modelado para  $I_{as}$ . Estas figuras confirman que el proceso de identificación fue exitoso. Así mismo, una comparación de los parámetros de la Tabla 3 con aquellos reportados para un motor del mismo modelo en [15] revela que estos son similares, lo cual ratifica la eficacia del algoritmo basado en *NGEDA*. Finalmente, la Tabla 3 también muestra que los niveles de error de modelado de la corriente  $I_{as}$  son similares a los de  $F_z$  del ejemplo anterior. Cabe notar que para  $I_{bs}$  los resultados son muy similares. En este caso se omite el error porcentual absoluto medio ya que en esta aplicación las señales cruzan por cero constantemente, provocando problemas numéricos al calcular este parámetro.

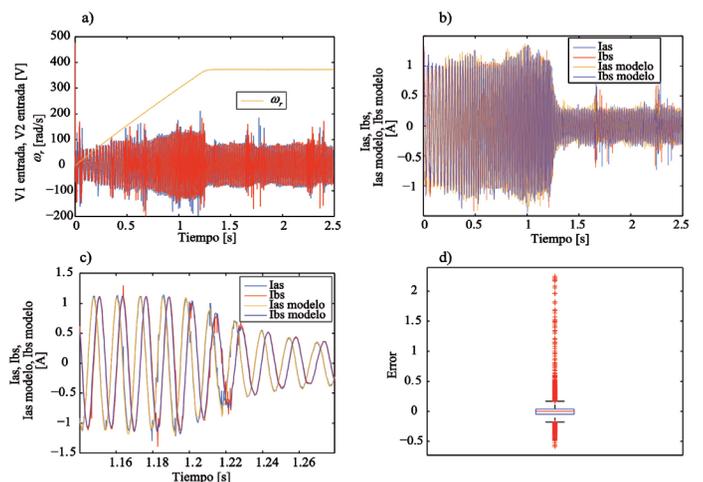


Fig. 5. (a) Voltajes del estator  $V_1$ ,  $V_2$  y velocidad del rotor  $\omega_r$ , (b) Comparación entre corrientes del estator, medidas experimentalmente y del modelo, (c) Acercamiento de las corrientes del estator durante la etapa de establecimiento del motor, (d) Gráfico de caja del error de modelado para  $I_{as}$

## 6. CONCLUSIONES

Las *NGEDA* se han propuesto con el objetivo de imitar algunos comportamientos complejos observados en las neuronas biológicas con la expectativa de que las *NGEDA* puedan ser utilizadas para aplicaciones complejas. En este artículo se ha mostrado experimentalmente que las *NGEDA* son efectivas para realizar identificación paramétrica.

En particular, se mostró que si se lleva a cabo una parametrización apropiada del modelo a identificar, es posible asignar los pesos de algunas *NGEDA* dentro de una red a los parámetros del modelo. De tal manera que al entrenar la red de *NGEDA* se obtienen los parámetros del sistema. Este método se probó tanto con un modelo lineal sin memoria como con un modelo dinámico no lineal.

La primera aplicación consistió en identificar los parámetros de un sistema de propulsión para un vehículo aéreo no tripulado. Aunque el modelo a identificar es simple, el sistema experimental está sujeto a un nivel importante de perturbaciones en las mediciones (vibraciones) y a complejas dinámicas no modeladas debidas a fenómenos aerodinámicos difíciles de modelar. A pesar de estas dificultades la identificación basada en *NGEDA* fue efectiva.

Otra aplicación más cercana a la industria consiste en la identificación de los parámetros del subsistema eléctrico de un motor de inducción. Estos parámetros son necesarios para diseñar sistemas de control de alto desempeño. La principal dificultad es que se trata con un sistema dinámico no lineal, donde los parámetros más importantes están relacionados con variables que no se miden directamente (flujo del rotor). Así mismo, las mediciones de corriente normalmente están sujetas niveles de ruido considerables. En este caso la identificación basada en *NGEDA* también mostró ser efectiva.

Los resultados mostrados en este artículo sugieren que las *NGEDA* tendrán un amplio rango de aplicación en lo que respecta a identificación de sistemas en el futuro, aplicación que apenas se ha empezado a explorar.

## BIBLIOGRAFÍA

[1] González-Sánchez M, Amézquita-Brooks L, Liceaga-Castro E, Zambrano-Robledo P. del C. "Simplifying quadrotor controllers by using simplified design models", IEEE CDC, 2013. DOI: 10.1109/CDC.2013.6760540. <https://doi.org/10.1109/CDC.2013.6760540>

[2] Luo J, Zhu L, Yan G. "Novel Quadrotor Forward-Flight Model Based on Wake Interference", AIAA Journal, Vol. 53, No. 12, December 2015, p. 3522-3533. DOI: 10.2514/1.J053011. <https://doi.org/10.2514/1.J053011>

[3] Hee-Lee C. "Design, Analysis, and Experimental Investigation of a Cyclocopter with Two Rotors", Journal of Aircraft, Vol. 53, No. 5, September-October 2016, p. 1527-1537. DOI: 10.2514/1.C032731. <https://doi.org/10.2514/1.C032731>

[4] Do Nascimento D.A, Rufino C.Z, Oliveira S.C, Feitosa M.A.F. "Modeling and Design of an Autonomous Unmanned Aerial Vehicle Quadrotor Prototype for Applications in Swarm of Robots", Robotics Symposium and Latin American Robotics Symposium, Brazil, 2012, DOI: 10.1109/SBR-LARS.2012.60. <https://doi.org/10.1109/SBR-LARS.2012.60>

[5] Gonzalez I, Salazar S, Romero H, Lozano R, Torres J. "Attitude control of a quad-rotor using speed sensing in brushless DC motors", International Conference on Electrical Engineering Computing Science and Automatic Control, 2011. DOI: 10.1109/ICEE.2011.6106621 <https://doi.org/10.1109/ICEE.2011.6106621>

[6] Beji L, Abichou A. "Trajectory Generation and Tracking of a Mini-Rotorcraft," Robotics and Automation, Proceedings of the 2005 IEEE International Conference on, ICRA, 2005, DOI: 10.1109/ROBOT.2005.1570508. <https://doi.org/10.1109/ROBOT.2005.1570508>

[7] Pipatpaibul P, and Ouyang P. R. "Application of Online Iterative Learning Tracking Control for Quadrotor UAVs", ISRN Robotics, Vol. 2013, DOI: 10.5402/2013/476153. <https://doi.org/10.5402/2013/476153>

[8] Castillo P, Dzul A, Lozano R. "Real-time stabilization and tracking of a four-rotor mini rotorcraft," IEEE Transactions on Control Systems Technology, Vol.12, No.4, July 2004, p. 510-516. DOI: 10.1109/TCST.2004.825052. <https://doi.org/10.1109/TCST.2004.825052>

[9] Cowling I. D, Yakimenko O. A, Whidborne J. F, & Cooke. "A. K. A prototype of an autonomous controller for a quadrotor UAV". 4th European Control Conference, 2007.

[10] Fabela R, Santana C, Naranjo A, Amezcua-Brooks L, Liceaga-Castro E. and Torres-Reyna

M. "Experimental characterization of a small and micro unmanned aerial vehicle propulsion systems", AIAA Atmospheric Flight Mechanics Conference, USA, 2016, DOI: 10.2514/6.2016-1530. <https://doi.org/10.2514/6.2016-1530>

[11] López R, Salazar S, González-Hernández I. and Lozano R. "Real-Time Parameters Identification for a Quad-rotor Mini-aircraft Using Adaptive Control", International Conference on Unmanned Aircraft Systems (ICUAS), USA, 2014, DOI: 10.1109/ICUAS.2014.6842291. <https://doi.org/10.1109/ICUAS.2014.6842291>

[12] Martínez O, Amezcua-Brooks L, Liceaga-Castro E, García-Salazar O. and Martínez D. "Experimental assessment of wind gust effect on PVTOL aerial vehicles using a wind tunnel", Electronics, ROPEC, 2015. DOI: 10.1109/ROPEC.2015.7395094. <https://doi.org/10.1109/ROPEC.2015.7395094>

[13] Ramírez Mendoza A. M. E. "Study of the state of art in experimental aerodynamics testing with unmanned aerial vehicles, UAVs in Mexico", Tecnologías Modernas para la Industria y la Educación, XIII Congreso Internacional sobre Innovación y Desarrollo Tecnológico, México, 2016.

[14] B. K. Bose, Modern Power Electronics and AC Drives (Prentice Hall, 2002)

[15] Amezcua-Brooks, L; Liceaga-Castro, J; Liceaga-Castro, E. Speed and Position Controllers Using Indirect Field-Oriented Control: A Classical Control Approach, IEEE Transactions on Industrial Electronics, Vol. 61, Iss. 4, 2014. DOI: 10.1109/TIE.2013.2262750 <https://doi.org/10.1109/TIE.2013.2262750>

[16] J. Holtz, T.Himm, Identification of machine parameters in a vector controlled induction motor drive, IEEE Transactions on Industry Application, Volume 27, Issue 6, Nov/Dec 1991, pp. 1111-1118 <https://doi.org/10.1109/28.108462>

[17] A. M. Khambadkone, J. Holtz, Vector Controlled Induction Motor Drive with a Self-Commissioning Scheme, IEEE Trans. Ind. Elec. Vol 38, Oct. 1991, pp. 322-327. DOI: 10.1109/41.97551 <https://doi.org/10.1109/41.97551>

[18] Peng C, Bai Y, Gong X, Gao Q, Zhao C, and Tian Y. "Modeling and Robust Backstepping Sliding Mode Control with Adaptive RBFNN for a Novel Coaxial Eight-rotor UAV", IEEE/CAA Journal of Automatica Sinica, Vol. 2, No. 1, January 2015. DOI: 10.1109/JAS.2015.7032906. <https://doi.org/10.1109/JAS.2015.7032906>

[19] Dierks T, Jagannathan S. "Output Feedback Control of a Quadrotor UAV using Neural Networks", IEEE Transactions on Neural Networks, Vol. 21, No. 1, January, 2010. DOI: 10.1109/TNN.2009.2034145. <https://doi.org/10.1109/TNN.2009.2034145>

[20] Pedro J. O, and Crouse A. J. "Direct Adaptive Neural Control of a Quadrotor Unmanned Aerial Vehicle", IEEE, 2015, IEEE 978-1-4799-7862-5/15. DOI: 10.1109/ASCC.2015.7244733. <https://doi.org/10.1109/ASCC.2015.7244733>

[21] Li L, Sun L, and Jin J. "Survey of Advances in Control Algorithms of Quadrotor Unmanned Aerial Vehicle", ICCT Conference Proceedings, 2015, DOI: 10.1109/ICCT.2015.7399803. <https://doi.org/10.1109/ICCT.2015.7399803>

[22] Martínez-Camara E, Jimenez-Macias E, Blanco-Fernandez J, et al. "Failure Detection and Prediction in Wind Turbines by using SCADA data", DYNA Energía y Sostenibilidad, Enero-Diciembre 2013, vol. 2, no. 1, [10 p.] DOI: 10.6036/ES5708. <http://dx.doi.org/10.6036/ES5708>

[23] Winter-Althaus G, Gonzalez-Landín B, Pulido-Alonso A, et al. "Forecasting Electricity Consumption including data of the present Economic and Financial Crisis. Application to Canary Islands" DYNA Energía y Sostenibilidad. Enero-Diciembre 2015, vol. 4, no. 1, [13 p.] DOI: 10.6036/ES7782 <https://doi.org/10.6036/ES7782>

[24] Pérez J. L, Ramírez A. "Two New Models of Integrative Fuzzy Neuron", Instrumentation & Development, Vol. 5, Nr.3, December, 2001

[25] Ramírez A, and Pérez J. L. "A Fuzzy Gupta Integrator Neuron Model with Spikes Response and Axonal delay", In Advances in Artificial Intelligence & Engineering Cybernetics, George E. Lasker (Ed.), IX, Windsor, Canada: IIAS, 2002

[26] Ramírez-Mendoza A, Pérez-Silva J. L, and Lara-Rosano F. "Electronic Implementation of a Fuzzy Neuron Model with a Gupta Integrator", Journal of Applied Research and Technology, 9(3), December 2011, p. 380-393, [http://cibernetica.ccadet.unam.mx/jart/vol9\\_3/electronic\\_10.pdf](http://cibernetica.ccadet.unam.mx/jart/vol9_3/electronic_10.pdf)

[27] Ramírez-Mendoza A. "Study of the response of the connection of Adaptive Fuzzy Spiking Neurons with self-synapse in each single neuron", 11th International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE), México, 2014. DOI: 10.1109/ICEE.2014.6978330 <https://doi.org/10.1109/ICEE.2014.6978330>

[28] Ramírez-Mendoza A. "Adaptive Fuzzy Spiking Neurons with Application for the Design of the PID Control Law", (en revisión para su publicación).

[29] A. Ramírez-Mendoza, "XOR with Neural Networks based on Adaptive Fuzzy Spiking Neurons", (en revisión para su publicación).

[30] Söderström T, Stoica P. System Identification, Prentice Hall International (UK) Ltd., 1989.

[31] Jategaonkar R.V. Flight Vehicle System Identification: A Time Domain Methodology, Volume 216 Progress in Astronautics and Aeronautics, American Institute of Aeronautics and Astronautics, Inc, Reston, Virginia, 2006.

[32] Kirsch B, Alexopoulos A, Badreddin E, "Non-Linear Model Based Control and Parameter Identification of a Hex-Rotor UAV", IEEE International Conference on Systems, Man, and Cybernetics, Hungary, 2016. DOI: 10.1109/SMC.2016.7844632. <https://doi.org/10.1109/SMC.2016.7844632>

[33] Al-Shabi M. A, Hatamleh K. S, Asad Asad A. "UAV Dynamics Model Parameters Estimation Techniques: a Comparison Study", IEEE Jordan Conference on Applied Electrical Engineering and Computing Technologies (AEECT), 2013. DOI: 10.1109/AEECT.2013.6716436 <https://doi.org/10.1109/AEECT.2013.6716436>

[34] Chen W, Lai J, Liu M, Lv P, Liu J. "An improved model aided navigation method with online dynamics parameters estimation for Multicopter UAV", Proceedings of IEEE Chinese Guidance, Navigation and Control Conference, China, 2016.

[35] Beard R. W, McLain T. W, Small Unmanned Aircraft: theory and practice, Princeton University Press, USA, 2012. DOI: 10.1515/9781400840601

**MATERIAL SUPLEMENTARIO**  
**FUNCIONAMIENTO DE LAS NEURONAS GENERADORAS DE ESPIGAS DIFUSAS ADAPTATIVAS**

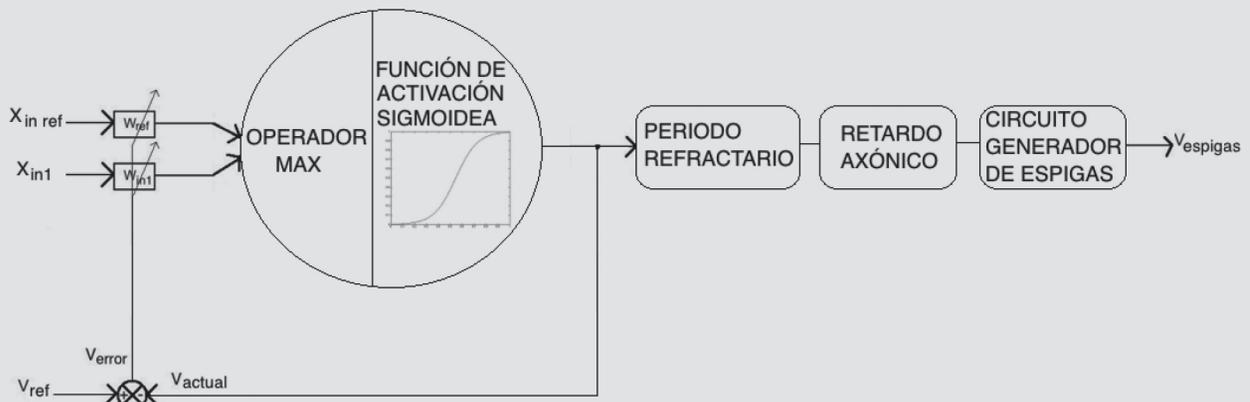


Fig. A.1. Neurona Generadora de Espigas Difusa Adaptativa (NGEDA)

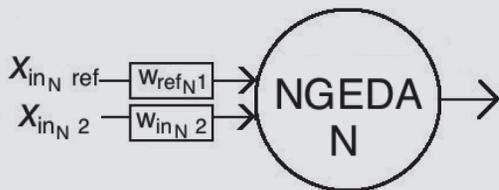


Fig. A.2. NGEDA, configuración para el método de identificación de parámetros del sistema

Para analizar las señales electrofisiológicas de las neuronas corticales motoras como son las neuronas generadoras de espigas rápidas se han propuesto algunos modelos para caracterizar las más importantes propiedades neuronales. Algunas de estas propiedades son la operación sináptica, la operación somática de agregación, la operación no lineal con umbral, el periodo refractario, el retardo axónico y la generación de espigas. El periodo refractario es el intervalo de tiempo después de la emisión de una espiga en el cual la neurona no responde a ninguna señal de entrada. El retardo axónico es el tiempo requerido para que la señal viaje a través del axón. El circuito generador de espigas con base en pulsos cuadrados y una señal o entrada de referencia produce espigas, [26].

La configuración de las NGEDA para la identificación de parámetros se muestra en la Fig. (A.1), mientras que en la Fig. (A.2) se muestra la representación simplificada utilizada en el artículo.

De acuerdo con los artículos [24-27], las operaciones neuronales básicas de las NGEDA son:

Sea el vector aumentado de entradas neuronales y pesos sinápticos para la lógica difusa unipolar es decir en el intervalo [0,1], representado por:

$$x_{in}(t) \in [0,1]^{n+1}, \quad w_{in}(t) \in [0,1]^{n+1},$$

a) La operación sináptica definida por la siguiente expresión,

$$z_i(t) = MIN(x_i(t), w_i(t)), \quad i = 1, 2, \dots, n \in [0,1]$$

donde el operador MAX es generalizado.

b) La operación somática de agregación se define,

$$v(t) = MAX_{i=0}^n [MIN(x_i(t), w_i(t))] \in [0,1]$$

donde el operador es generalizado.

c) Operación somática no lineal con umbral,

$$y(t) = \phi[v(t)] \in [0,1]$$

donde el mapeo no lineal  $\phi$  [-] puede ser una función de activación tipo escalón, sigmoidea o alguna otra función equivalente. El algoritmo de aprendizaje difuso para las NGEDA con una función de activación sigmoidea es propuesto en [27-29].