

Uso de un Sistema Neurodifuso para la Determinación del Contenido de Grasa en Ratas a Partir de su Impedancia Bioeléctrica

Emmanuel Ortega¹, Jeny Salazar-Anguiano¹, Esteban Ruíz¹, David Elías¹

¹Ingeniería Eléctrica, CINVESTAV,

Av. Instituto Politécnico Nacional 2508, Col. San Pedro Zacatenco, C.P. 07360, México, Ciudad de México.

Resumen—En este trabajo se presenta el diseño de un sistema de inferencia difuso (FIS) que puede calcular el contenido de grasa en ratas, teniendo como elementos de entrada el peso y la talla de las mismas, así como su impedancia eléctrica. Los parámetros de este sistema se optimizaron por medio de una red neuronal, utilizando la herramienta para sistemas de inferencia adaptativos neurodifusos (ANFIS) de MATLAB. Se utilizaron los datos de 17 ratas distintas, obteniéndose una correlación >0.99 entre el contenido real de grasa y la salida del sistema.

Palabras Clave—Impedancia eléctrica, sistemas neurodifusos.

I. INTRODUCCIÓN

Recientemente se ha reportado que el 70% de la población mexicana adulta presenta sobrepeso u obesidad, la cual deteriora gravemente la salud y es un factor de riesgo para desarrollar *diabetes mellitus* y problemas cardiovasculares [1,2]. Por este motivo es importante implementar diferentes métodos de análisis con el fin de desarrollar tratamientos anti-obesidad.

Una manera de estimar la cantidad de grasa de un ser vivo es mediante la medición de la impedancia (Z). Esta impedancia es la oposición de un conductor que se somete a un flujo de corriente eléctrico alterno, la cual está en función de la frecuencia del flujo. Z se determina con sus vectores relación: resistencia (R) y reactancia (X_c), en donde R es la oposición pura del conductor a la corriente alterna y X_c es la componente dieléctrica de la impedancia [3]. La resistencia de un material de un conductor eléctrico está relacionada con su área, la longitud y la resistividad. En el caso particular de los sistemas biológicos, cada tejido tiene su propia resistividad (ρ), pero se ha observado que la ρ de cada segmento del cuerpo o del total del cuerpo es la ρ promedio de los tejidos conductores. Por este motivo, se asume que su resistividad es constante para todo el cuerpo. Tomando en cuenta la impedancia del tejido, la obtención del volumen de un cuerpo puede aproximarse por la ecuación [4-6]:

$$V = L^2 / Z$$

dónde L es la longitud del cuerpo y Z la impedancia del mismo.

Los sistemas neurodifusos son la combinación de Redes neuronales y sistemas difusos, complementando sus virtudes y eludiendo las lagunas de cada una de ellos.

Los sistemas difusos combinan la Teoría de los Conjuntos Difusos y la Lógica Difusa y consigue reproducir comportamientos complejos, enunciados en forma de

relaciones cualitativas e imprecisas, propios del lenguaje natural, y expresarlos en términos numéricos. Su estructura básica consta de dos bloques: una Base de Reglas y una Máquina de Inferencia. La habilidad de los Sistemas Difusos, para incorporar a su estructura información lingüística “humana”, los hace atractivos para automatizar sistemas controlados por operadores humanos. Pero su deficiente especificación, por sus imprecisiones e incertidumbres del entorno en que se desarrollan, resultan difíciles y/o costosos de modelar con la simplicidad necesaria para ser tratados por otros métodos.

Las redes neuronales, son apropiadas para sistemas que procesan y adquieren automáticamente información numérica o que resuelven problemas de reconocimiento de patrones, a causa de su capacidad de aprendizaje y adaptación. Sin embargo, su modo de procesar la información resulta difícil de expresar en términos de lenguaje natural.

Los sistemas neurodifusos, son sistemas difusos que aprovechan métodos de ajuste propios de las redes neuronales. En este sistema se siguen identificando los bloques del sistema difuso. Las redes neuronales son utilizadas para aumentar y mejorar la capacidad de procesamiento del sistema difuso, en tareas como la definición y ajuste de las funciones de pertenencia, así como el diseño y ajuste de la base de reglas.

Diferentes problemas se han resuelto con estos sistemas, tal como la predicción de lluvias en primavera [7] usando datos como la presión del nivel del mar, la temperatura del nivel del mar, entre otras. Otro ejemplo es la determinación de grado en el síndrome de apnea obstructiva del sueño [8] teniendo como entradas la poligrafía cardiorrespiratoria nocturna, el índice de apnea hipopnea alterado, el porcentaje de tiempo de sueño y otros datos para la determinación síndrome de apnea.

Existen varios estudios para la determinación de grasa, la cantidad de agua, así como su masa magra, principalmente en humanos y en algunos casos en animales de estudio como ratas, conejos entre otros. Estos estudios usan métodos estadísticos, tal como las regresiones lineales, para obtener la estimación de grasa corporal principalmente con los datos de impedancia, talla y peso.

En este trabajo se plantea el uso de sistemas de inferencia difuso (FIS) así como los sistemas de inferencia adaptativos neurodifusos (ANFIS) de MATLAB como alternativa para la estimación de grasa corporal en ratas de laboratorio usando datos obtenidos en pruebas de medición de impedancias en ratas.

TABLA I
 Datos por triplicado de las 17 ratas usadas en el estudio.

Rata	Peso (g)			Talla (cm)			Contenido de grasa (g)			Impedancia (Ω)		
	1	2	3	1	2	3	1	2	3	1	2	3
1	320	306	351	22.0	23.0	23.0	117.6	102.2	136.1	681.55	441.90	633.70
2	333	356	387	22.0	24.0	24.0	123.1	138.9	154.5	540.39	734.64	550.47
3	337	330	357	22.5	24.0	24.0	125.5	119.2	137.5	311.33	552.00	619.07
4	349	386	408	22.0	24.0	24.0	132.3	147.1	168.2	510.64	374.59	577.67
5	317	350	351	22.0	25.0	25.0	114.2	132.0	131.4	588.99	616.07	566.69
6	316	336	368	22.0	23.0	23.0	113.9	122.8	142.2	606.10	502.77	487.98
7	319	332	357	22.0	23.0	23.0	116.5	122.4	137.3	649.73	586.83	559.83
8	325	322	355	22.5	24.0	24.0	119.3	113.7	134.9	623.77	532.05	559.77
9	345	350	386	23.0	24.0	24.0	131.8	134.2	154.0	657.68	673.63	555.08
10	333	362	376	22.0	24.0	24.0	123.5	137.2	150.2	558.46	489.46	666.85
11	346	352	387	22.0	24.0	24.0	132.6	135.7	158.1	611.65	688.80	733.28
12	351	382	397	23.0	24.0	24.0	131.5	152.2	165.3	482.82	582.76	807.80
13	331	365	378	23.0	24.0	24.0	119.8	141.2	151.8	505.90	563.74	687.61
14	344	332	379	22.5	24.0	24.0	130.7	120.4	147.8	603.30	550.47	491.27
15	344	395	388	23.0	24.0	24.0	126.7	159.8	157.8	468.56	540.73	675.92
16	338	320	368	23.0	23.0	23.0	125.5	114.3	145.4	558.97	603.32	620.77
17	297	310	332	22.0	23.0	23.0	102.3	106.8	124.6	616.16	506.96	712.91

II. METODOLOGÍA

A. Obtención de los datos

Las pruebas de medición de impedancias y obtención de grasa se realizaron a 17 ratas Sprague Dawley, en tres periodos diferentes (Tabla I). Las mediciones de sus tallas se tomaron de la base de la cola a la punta de la nariz de la rata. En la medición de la impedancia se utilizaron como electrodos agujas de acupuntura de acero inoxidable de 0.22 mm de largo y 13 mm de diámetro. Los electrodos se insertaron subcutáneamente a una distancia aproximada de 1 cm entre los electrodos de medición y los de excitación. El equipo utilizado en las pruebas fue desarrollado en el laboratorio específicamente para este fin [9].

B. Selección de los datos

De estos 51 datos, se seleccionaron de manera aleatoria 31 para entrenar el sistema neurodifuso y los 20 restantes para validar su desempeño, con la única condición que dentro de los datos de entrenamiento se encontraran los casos límite de los cuatro parámetros considerados: peso, talla, impedancia y contenido de grasa, es decir, sus valores máximos y mínimos.

C. Sistema de inferencia difuso

Se eligió un sistema de inferencia difuso del tipo Sugeno, de forma que pudiera ser optimizado utilizando la herramienta para sistemas de inferencia adaptativos neurodifusos (ANFIS) de MATLAB. Este sistema se diseñó con tres entradas (peso, talla e impedancia) y una salida (contenido de grasa).

Para la primera entrada correspondiente al peso, se asignaron 6 funciones de membresía del tipo gaussiano que catalogan el peso de las ratas en “muy bajo”, “bajo”, “medio bajo”, “medio alto”, “alto” y “muy alto”. El intervalo de valores para esta entrada está comprendido entre 290 y 410 g.

La segunda entrada, la talla, tiene sólo dos funciones de membresía que clasifican el tamaño de la rata en “chica” y “grande”, ambas del tipo gaussiano. El intervalo de entrada para éste parámetro es de 20 a 27 cm.

La tercera entrada, que corresponde a la impedancia de la rata, cuenta con cuatro funciones de membresía, igualmente del tipo gaussiano, que clasifican esta magnitud en “muy baja”, “media baja”, “media alta” y “alta”. El rango de entrada de la impedancia de la rata va de 300 a 900 Ω .

El contenido de grasa de la rata, es decir, la salida del sistema, se clasificó en seis niveles distintos: “muy poco”, “poco”, “promedio”, “promedio alto”, “alto” y “muy alto”, con valores iniciales de 0, 0.2, 0.4, 0.6, 0.8 y 1.0 respectivamente.

Las operaciones lógicas difusas seleccionadas fueron el producto (función *prod*) para el método AND, y el “or probabilístico” (función *probor*) para el método “OR”. Los métodos de implicación y agregación vienen dados de forma predeterminada por el mínimo y máximo respectivamente. Se escogió el promedio como método de defusificación.

D. Reglas de inferencia

Para relacionar las entradas con la salida se diseñaron seis reglas de inferencia que se resumen en las siguientes sentencias:

- Si el *peso* es *muy bajo* y la *talla* es *chica*, entonces el contenido de *grasa* es *muy poco*.
- Si el *peso* es *medio bajo* y la *impedancia* es *muy baja*, entonces el contenido de *grasa* es *poco*.
- Si el *peso* es *medio alto* y la *impedancia* es *media alta*, entonces el contenido de *grasa* es *promedio*.
- Si el *peso* es *bajo* y la *talla* es *grande* y la *impedancia* es *media baja*, entonces el contenido de *grasa* es *promedio alto*.

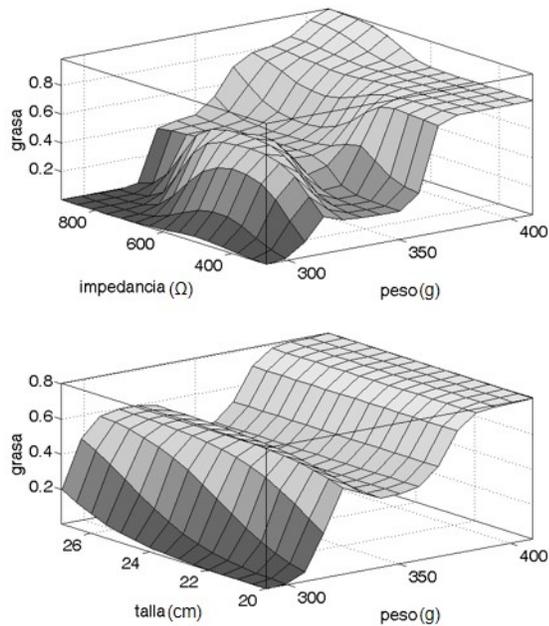


Fig. 1. Superficies de control del sistema de inferencia difuso Sugeno antes del entrenamiento. Arriba: Contenido de grasa con rango de [0 1] en función de la impedancia y el peso. Abajo: Contenido de grasa con rango de [0 1] en función de la talla y el peso.

- Si el *peso* es *alto*, entonces el contenido de *grasa* es *alto*.
- Si el *peso* es *muy alto* y la *impedancia* es *alta*, entonces el contenido de *grasa* es *muy alto*.

Estas reglas se basaron en los resultados obtenidos de las mediciones de impedancia respecto a su relación con el peso y la talla de las 17 ratas.

III. RESULTADOS

Una vez establecidas las reglas de inferencia y las funciones de membresía en la herramienta *FisEditor* de MATLAB, se obtuvieron las superficies de control de peso contra impedancia y de peso contra la talla de la rata (ambas antes del entrenamiento), con los 31 parámetros iniciales (Fig. 1).

A. Entrenamiento del sistema neurodifuso

Para entrenar el sistema neurodifuso se utilizó la herramienta *anfisedit* de MATLAB. Se cargaron los datos previamente seleccionados de entrenamiento y validación, así como el sistema de inferencia difuso diseñado, cuya estructura se muestra en la Fig. 2.

Se seleccionó el tipo de entrenamiento híbrido y se configuraron la tolerancia de error igual a cero y el número de iteraciones igual a diez en la herramienta *anfisedit*.

Los parámetros del sistema de inferencia difuso se ajustaron de forma correcta en relación a los datos de entrenamiento obtenidos de *anfisedit* que se aprecian en la Fig. 3.

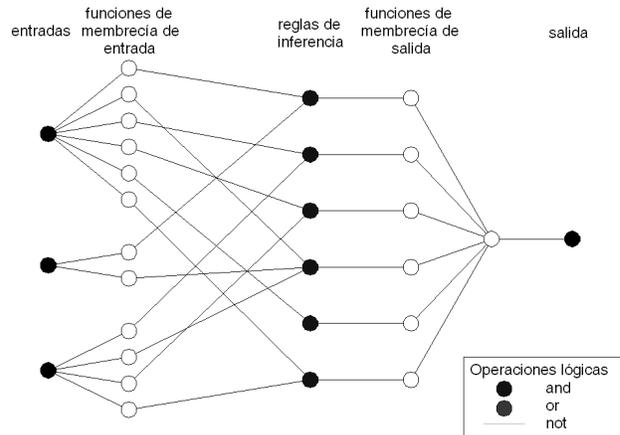


Fig. 2. Estructura del sistema de inferencia neurodifuso. Presenta el conjunto de 6 reglas que permiten entrenar las redes neuronales.

Para verificar que el sistema no haya sido sobreentrenado y que funciona con datos diferentes a los utilizados para su entrenamiento, se probó este sistema de inferencia difuso correlacionándolo con diferentes datos de validación previamente seleccionados observando su comportamiento en la Fig. 4.

Estos mismos datos de validación se reordenaron de forma aleatoria para verificar que no existiera ninguna tendencia en la salida del sistema. Como se observa en la Fig. 5, el sistema de inferencia diseñado responde de manera satisfactoria.

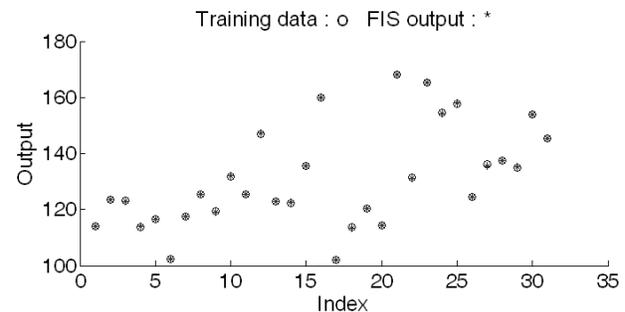


Fig. 3. Resultado del entrenamiento *anfisedit* de MATLAB. Se grafican los 31 datos de contenido de grasa utilizados para el entrenamiento (o) contra la salida del sistema (*) con un error 0.15258.

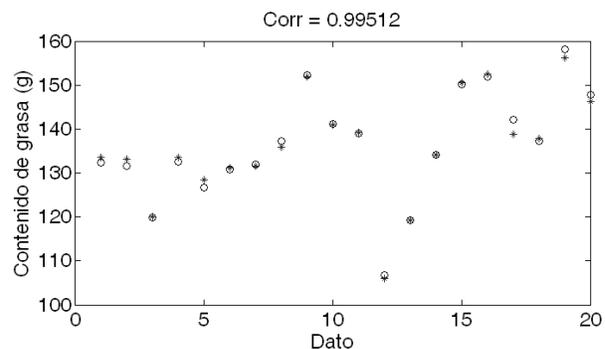


Fig. 4. Resultado de la validación del sistema. Se grafican los 20 datos de contenido de grasa reservados para probar el sistema (o) contra la salida del sistema (*).

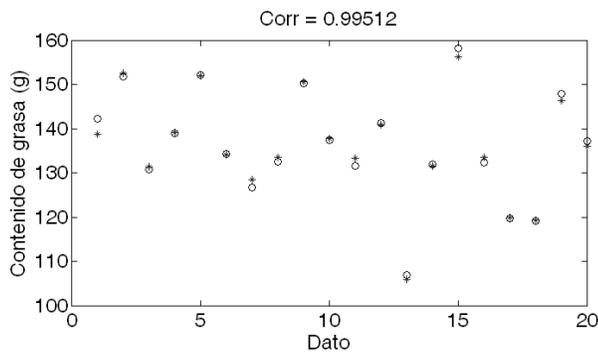


Fig. 5. Gráfica de los datos de contenido de grasa usados en la validación del sistema, reordenados de manera aleatoria (o) contra la salida del sistema (*).

Las superficies de control o difusas de peso contra impedancia y de peso contra talla, con los parámetros optimizados, después del entrenamiento, estos datos se adaptaron a las 6 reglas de inferencia, mostrando su superficie en la Fig. 6.

IV. DISCUSIÓN

El sistema de inferencia presentado comprueba en la Fig. 4 que no fue sobreentrenado y que su respuesta es bastante buena, con un coeficiente de correlación entre el contenido de grasa real de las ratas y el calculado por el sistema de 0.995. Lo mismo sucede con los datos de validación ordenados aleatoriamente con un coeficiente de correlación también de 0.995, Fig. 5.

Este análisis de datos está construido con entradas características para la determinación de grasa corporal, se podrían agregar otras entradas como el índice de masa corporal y/o la circunferencia de la cintura para obtener una estimación más acertada del porcentaje de grasa corporal. Con la inclusión de estas dos variables se presentarían nuevas superficies de control debido a estas dos nuevas entradas al sistema y al cambio de las reglas de inferencia por las mismas entradas.

V. CONCLUSIONES

Se diseñó un sistema neurodifuso capaz de predecir el contenido de grasa en ratas, conociendo su peso, talla e impedancia eléctrica con una buena precisión (coeficiente de correlación mayor de 0.99). La salida de dicho sistema aparentemente no presenta sobreentrenamiento ni tendencias en las salidas, aunque sería recomendable validarlo con un número mayor de datos. Este sistema se podría implementar con datos de población mexicana para la estimación de grasa corporal o más aún para el desarrollo de tratamientos anti-obesidad.

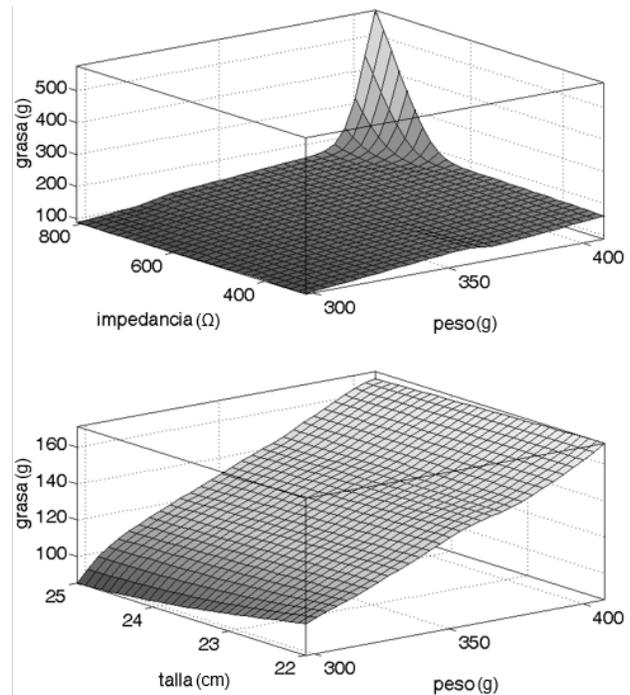


Fig. 6. Superficies de difusas del sistema de inferencia difuso Sugeno después del entrenamiento. Arriba: Contenido de grasa en función de la impedancia y el peso. Abajo: Contenido de grasa en función de la talla y el peso.

REFERENCIAS

- [1] S. Barquera, I. Campos-Nonato, L. Hernández-Barrera, et al., "Obesity and central adiposity in Mexican adults: results from the Mexican Nation Health and Nutrition Survey 2006", *Salud Publ Mex*, vol. 51, pp S595-S607, Mar. 2009.
- [2] (2014) UNICEF sitio web. [Online]. Disponible: <http://www.unicef.org/mexico/spanish/17047.htm>.
- [3] H. C. Lukaski, "Biological index considered in the derivation of the bioelectrical impedance analysis", *Am J Clin Nutr*, pp 397S-404S, 1996.
- [4] Earl C. Hoffer, Clifton K. Meador y David C. Simpson, "Correlaton of whole body impedance with total body water volume," vol. 27, no. 4, pp. 231-534, 1969
- [5] Lee E. Baker, "Principles of the Impedance Technique," *IEEE Engineering in Medicine and Biology Society*, vol. 8, no. 1, pp. 11-15, 1989.
- [6] Steven B. Heymsfield, Timothy G. Lohman, Wang ZiMian, y Scott B. Going, *Human Body Composition*, Segunda ed. Estados Unidos: Human Kinetics, 2005.
- [7] Fallah-Ghahary, G.A., Habibi-Nokhandan, M., Mousavi-Baygi, M. et al., "Spring rainfall prediction based on remote linkage controlling using adaptive neuro-fuzzy inference system (ANFIS)", *Theor Appl Climato*, vol. 101, no. 1, pp. 217-233, 2010
- [8] Polat, K., Yosunkaya, Ş. & Güneş, S., "Pairwise ANFIS Approach to Determining the Disorder Degree of Obstructive Sleep Apnea Syndrome", *J Med Syst.*, vol. 32, no. 5, pp 379-387, 2008
- [9] J. Salazar-Anguiano, "Diseño y Construcción de un Sistema de Impedanciometría para la Determinación de Grasa Corporal en Ratas de Laboratorio" Tesis de M. en C., CINVESTAV-IPN, D.F., México, Nov. 2011.