

Estimación del porcentaje de grasa corporal mediante redes neuronales

Estimation of body fat percentage using neural networks

Freddy García*
Jonathan Espinosa**

Fecha de recepción: 30 de marzo 2013
Fecha de aceptación: 30 de abril de 2013

Resumen

En este artículo se presenta la estimación del porcentaje de grasa corporal usando redes neuronales. Se exploran dos métodos distintos para la clasificación y la estimación, el de MLP y el de SOM. Mostrando la metodología usada en cada uno y el mejor resultado obtenido, para finalmente comparar los resultados logrados y concluir.

Palabras Clave

Redes neuronales, MLP, SOM, grasa corporal, MATLAB.

Abstract

This paper presents the estimation of body fat percentage using neural networks. We explore two different methods for classification and estimation, the MLP and SOM. Showing the methodology used in each and the best result. Finally we compare the results achieved and conclude.

Key words:

Neural networks, MLP, SOM, body fat, MATLAB.

* Universidad Distrital Francisco José de Caldas. Correo electrónico: frganigr@gmail.com

** Universidad Distrital Francisco José de Caldas. Correo electrónico: jespinosal@hotmail.es

1. Introducción

Los problemas relacionados con la cantidad de grasa en la composición del cuerpo humano en general están aumentando significativamente, las razones pueden estar asociadas a problemas de desnutrición, como la obesidad y el sobrepeso, situación que afecta a la salud mundial. Claramente, el sobrepeso no se puede tomar a la ligera. El problema de la obesidad es un asunto de gran preocupación para el individuo y las autoridades gubernamentales. La obesidad incrementa la posibilidad de mortalidad en todas las edades; el exceso de grasa se considera un perjuicio para la condición física y el rendimiento laboral de las personas, en lo que incide una serie de variables distintas como la edad, el sexo, la formación, la actitud y la motivación, la genética y los factores ambientales. La obesidad se considera como una condición en la que se presenta una acumulación excesiva de grasa corporal en el cuerpo.

Por lo tanto, la evaluación de la cantidad de grasa en la composición del cuerpo humano, es un elemento clave en el tratamiento de estos problemas. Aunque una variedad de métodos y técnicas se han desarrollado para la evaluación de la composición corporal, incluyendo el porcentaje de grasa corporal, ninguno puede ser considerado como una única y completa solución ideal.

La estimación de la grasa en el cuerpo humano tiene muchas aplicaciones en diferentes áreas de la medicina y otras pruebas de aptitud física. La consideración de múltiples factores tales como los costos involucrados con el equipo, los efectos que tienen sobre las personas, la aptitud en gran escala y evaluaciones sistemáticas, combinado con la precisión de las evaluaciones realizadas, dan lugar a la existencia y perfeccionamiento de diversos métodos.

La forma más precisa de cálculo del porcentaje de grasa corporal es la prevista por la ecuación de *Siri*, que requiere una medida de la densidad a través de ponderación bajo el agua, siendo un método caro y poco práctico.

La antropometría sigue siendo la técnica no invasiva más aplicable para identificar estados de desnutrición, de muestras clínicas y no clínicas. Es una técnica común, sencilla y barata, aplicable en un gran número de personas, la cual se basa en la medición del espesor del pliegue cutáneo usando calibradores de pliegues cutáneos por observadores entrenados.

El problema es que, tomar la medición del pliegue cutáneo es muy tedioso y puede dar lugar a mediciones inexactas, además debe ser realizado por técnicos de salud capacitados y siguiendo procedimientos estándar.

Igualmente hay métodos simples y rentables que utilizan la edad y las mediciones de la circunferencia del cuerpo que son fáciles de obtener sin muchos errores de medición. Al lado de ellos, hay una gran cantidad de métodos estadísticos y de fórmulas para calcular el porcentaje de grasa en el cuerpo humano en base a estas mediciones.

En este trabajo hemos propuesto un modelo basado en redes neuronales para la estimación de la grasa corporal mediante las sencillas medidas de las circunferencias, usando diferentes técnicas como SOM y MLP. Para finalmente hacer una comparación de ambas técnicas y así observar cual presenta mejores resultados para nuestro problema en específico.

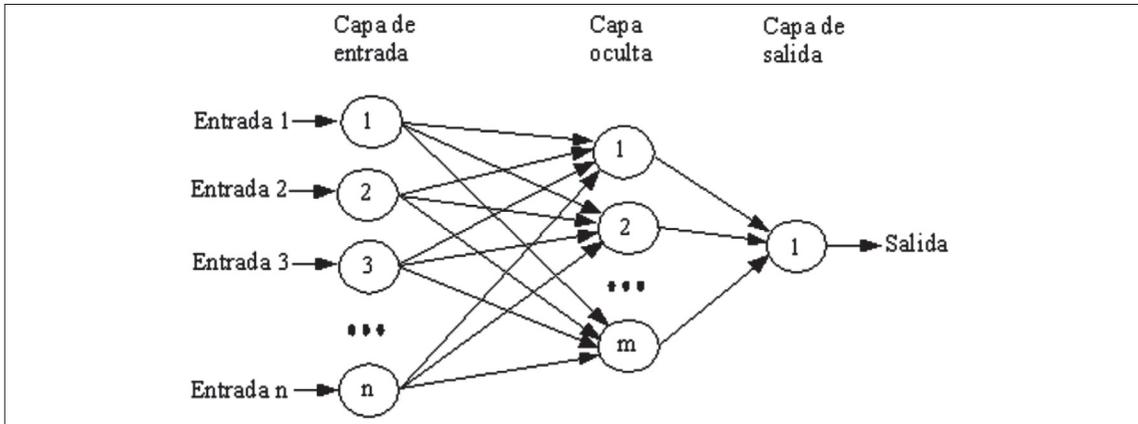
2. Marco teórico

Una red neuronal se compone de unidades llamadas neuronas; cada neurona recibe una serie de entradas a través de interconexiones y emite una salida. En la figura 1 se muestra un ejemplo de una red neuronal, la cual consta de una capa de entrada, una capa oculta y una de salida.

2.1. Redes neuronales MLP

El perceptrón multicapa es un aproximador universal de relaciones no lineales entre datos de entrada y de salida. Históricamente se ha aplicado con éxito en numerosas aplica-

Figura 1. Modelo general de una red neuronal perceptrón.



Fuente: elaboración propia.

ciones como reconocimiento de voz e imágenes. Aunque su tiempo de aprendizaje es bastante lento, el perceptrón multicapa es realmente efectivo cuando las instancias están representadas por muchos pares atributo-valor.

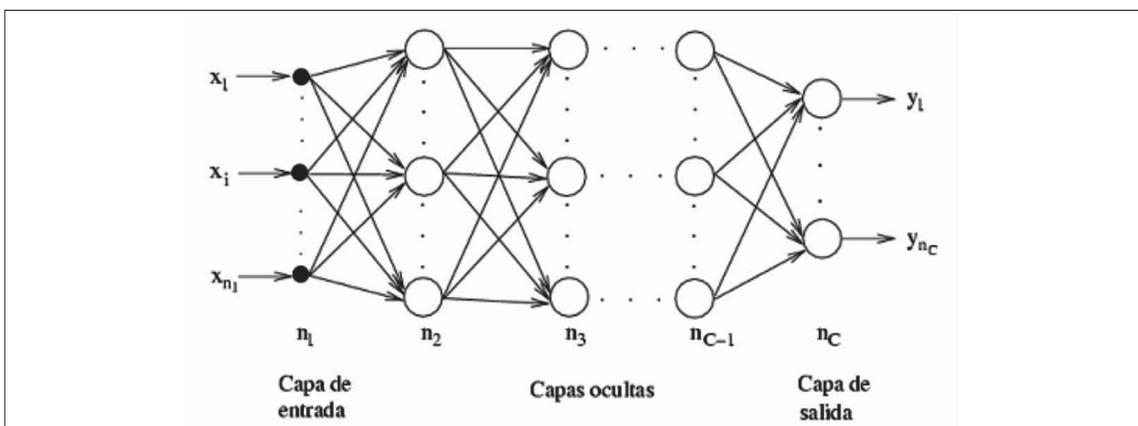
La arquitectura típica de un perceptrón multicapa se muestra en la figura 2, ésta consiste de tres partes: una capa de entrada, una capa de salida y una o varias capas ocultas.

El perceptrón multicapa se caracteriza por presentar una no linealidad en la salida y un alto grado de conectividad. Es de entrena-

miento supervisado. Utiliza el algoritmo de *back propagation*. Este algoritmo está basado en la regla de aprendizaje por corrección de error, considerada como una generalización del algoritmo de los cuadrados mínimos (LMS).

Su operación consta de dos fases, una directa y una inversa o de retroceso. En la fase directa, se ingresa el patrón de actividad en la capa de entrada de la red (vector de entrada), que recorre todas las capas subsiguientes. En la fase inversa, los pesos sinápticos son ajustados de acuerdo con la regla de corrección del error.

Figura 2. Arquitectura típica de un perceptrón multicapa



Fuente: elaboración propia.

2.2. Redes neuronales SOM

En 1982 T. Kohonen presentó un modelo de red denominado mapas auto-organizados o SOM (Self-Organizing Maps), basado en ciertas evidencias descubiertas a nivel cerebral. Este tipo de red posee un aprendizaje no supervisado y competitivo.

La red auto-organizada debe descubrir rasgos comunes, regularidades, correlaciones o categorías en los datos de entrada, e incorporarlos a su estructura interna de conexiones.

Se dice, por tanto, que las neuronas deben auto-organizarse en función de los estímulos (datos) procedentes del exterior.

En el aprendizaje competitivo las neuronas compiten unas con otras con el fin de llevar a cabo una tarea dada. Se pretende que cuando se presente a la red un patrón de entrada, sólo una de las neuronas de salida (o un grupo de vecinas) se active. Por tanto, las neuronas compiten por activarse, quedando finalmente una como neurona vencedora y el resto anuladas, las cuales son forzadas a sus valores de respuesta mínimos.

El objetivo de este aprendizaje es categorizar los datos que se introducen en la red. Se

clasifican valores similares en la misma categoría y, por tanto, deben activar la misma neurona de salida.

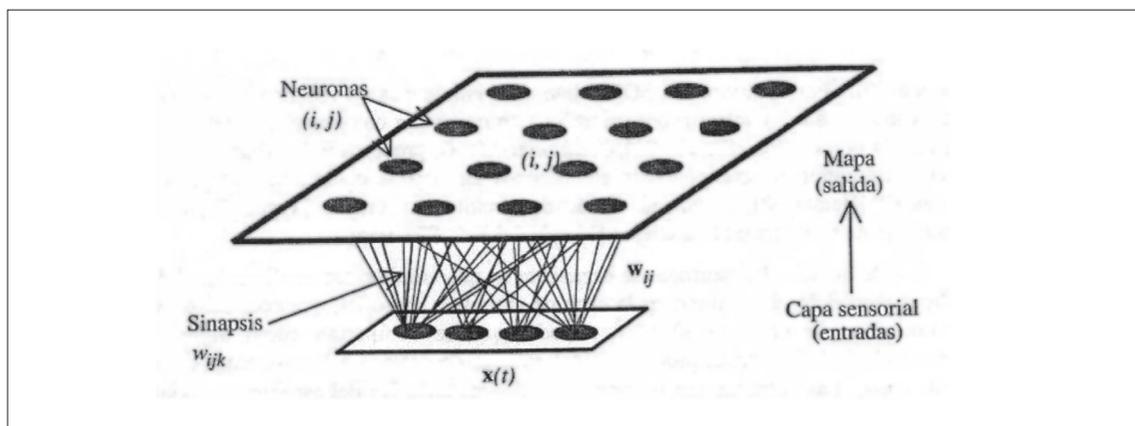
Un modelo SOM está compuesto por dos capas de neuronas. La capa de entrada (formada por n neuronas, una por cada variable de entrada) se encarga de recibir y transmitir a la capa de salida, la información procedente del exterior. La capa de salida (formada por m neuronas) es la encargada de procesar la información y formar el mapa de rasgos. Normalmente, las neuronas de la capa de salida se organizan en forma de mapa bidimensional como se muestra en la figura 3.

3. Base de datos

El modelo propuesto ha sido probado con los datos de las grasas del cuerpo humano, distribuido por Roger W. Johnson del Departamento de Matemáticas y Ciencias de la Computación y Escuela de Datos y Tecnología (South Dakota). Este conjunto de datos ha sido proporcionado originalmente por el Dr. A. Garth Fisher (comunicación personal, 5 de octubre de 1994).

Consta de los siguientes datos: edad, peso, altura y circunferencia de 10 mediciones corporales que se registraron para 252 hombres.

Figura 3. Arquitectura típica de una red SOM



Fuente: elaboración propia.

El porcentaje de grasa corporal de cada uno se estima con precisión por la técnica del peso bajo el agua y la densidad, también se proporciona el porcentaje medido de grasa corporal junto con los datos.

Todas las variables de la base de datos son las siguientes:

- Edad (Años)
- Peso (Libras)
- Altura (Pulgadas)
- Circunferencia del cuello (cm.)
- Circunferencia del pecho (cm.)
- Circunferencia del abdomen (cm.)
- Perímetro de la cadera (cm.)
- Circunferencia del muslo (cm.)
- Circunferencia de la rodilla (cm.)
- Circunferencia del tobillo (cm.)
- Circunferencia del bíceps (extendido) (cm.)
- Circunferencia del antebrazo (cm.)
- Circunferencia de la muñeca (cm.)
- Porcentaje de grasa corporal de la ecuación de *Siri* (%)
- Densidad determinada de peso bajo el agua (cm.)

Estos datos se utilizan para entrenar las redes. Se toman todas las medidas del cuerpo como variables. Además se usa la variable 14 (el porcentaje de grasa) como referencia para crear las clases.

El valor de la densidad (15) es un valor que se da sólo como información y no va a ser utilizado para la el entrenamiento o las pruebas.

4. Metodología

Se pretende dar solución al problema de la estimación de la grasa corporal humana mediante la implementación de las técnicas MLP y SOM. Los antecedentes del problema son escasos, para simplificar el problema y facilitar al usuario el entendimiento del diagnóstico proporcionado por las redes neuronales se planteó el problema en base a la clasificación especificada en la tabla 1.

En la tabla 1 se pueden apreciar cinco clases que son determinadas en función de la edad y el porcentaje de la grasa corporal del hombre, así cada usuario puede tener una estimación de su desviación del porcentaje de grasa ideal, cuya clase característica es “recomendado”, y tomar las medidas pertinentes para corregirlo a tiempo.

A continuación se expone la metodología desarrollada en cada una de las técnicas a implementar.

4.1. Estimación del porcentaje de grasa corporal implementado MLP

En base al problema planteado anteriormente, introducimos a una red de perceptrón multicapa (MLP) la base de datos proporcionada, seleccionando el 70 % de los datos para realizar el entrenamiento de la red neuronal, y utilizado el 30 % restante para realizar el respectivo test.

Tabla 1. Clasificación del porcentaje de grasa corporal

	Edad	Bajo	Recomendado	Alto	Muy alto
Hombre	20-39	5-7	8-20	21-25	>25
	40-59	5-10	11-21	22-27	>27
	60-79	5-12	13-25	26-30	>30

Fuente: elaboración propia.

Durante el entrenamiento se pretende realizar una serie de experimentos modificando variables pertinentes a la red, tales como el algoritmo de entrenamiento implementado, número de neuronas en la capa oculta, tasas de entrenamiento, número de épocas y número de capas ocultas en la red, analizando así sus respectivas tasas de clasificación y errores cuadráticos medios, obtenidos para poder evaluar el desempeño de la red en dichas condiciones.

La iniciación de los pesos y del bias en la red se realizara de manera aleatoria, pues no es fácil encontrar antecedentes que nos permitan realizar una estimación para la inicialización de estos componentes.

Para la variación del número de neuronas en la capa oculta se realizará un barrido, sumando cinco neuronas a la vez por experimento, este experimento será realizado sucesivamente, deteniéndolo en el instante donde se considere que el aumento del número de neuronas no representa una mejora significativa en la tasa de clasificación y su error cuadrático medio.

Los algoritmos de entrenamiento a implementar se enumeran a continuación:

- Levenberg-Marquardt Backpropagation.
- Gradient descent whit momentum an adaptive learning rate Backpropagation.
- Conjugate gradient Backpropagation.
- OneStepSecant.

4.2. Estimación del porcentaje de grasa corporal implementado mapas auto-organizados

A continuación se pretende resolver el problema mediante el uso de redes SOM, la distribución de los datos para entrenamiento y test es la misma elegida en el proceso anterior (MLP), adicionalmente por tratarse de una técnica de aprendizaje no supervisado se debe suprimir el vector de entrada de la base de datos que representa el porcentaje

de grasa. Otro tratamiento previo que recibe la red es un “bautizo” que se realiza mediante etiquetas, las cuales representan la clase correspondiente de cada ejemplo de la base de datos del grupo “Entrenamiento”, que corresponde al 70 % de los datos.

Se pretende realizar una serie de experimentos con el fin de obtener la configuración de red mas optima para dar solución a este problema, esto mediante la variación de parámetros de la red y el entrenamiento en el tipo de normalización empleada en la base de datos, el número de neuronas en el mapa, la topología, el algoritmo de entrenamiento y la inicialización.

El rango de variación del número de neuronas del mapa se determinara en función de la siguiente expresión:

$$\# \text{ neuronas} = 5 * \# \text{ instancias} \quad (1)$$

Inicialmente se experimenta, alternando el tipo de normalización de datos, para posteriormente realizar experimentos variando la cantidad de neuronas por encima y por debajo del valor de la expresión mencionada, y así encontrar la mejor respuesta de red en función de este parámetro.

Se realizarán experimentos mediante la implementación de los algoritmos *Batch* y *Secuencial*, y pruebas, cambiando el tipo de topología, rectangular y hexagonal.

La inicialización se realizará de manera aleatoria por las mismas razones expresadas en el método anterior (MLP).

5. Resultados

Implementando las técnicas mencionadas se obtuvieron los siguientes resultados:

5.1. Estimación del porcentaje de grasa corporal implementado en MLP

En el primer experimento se mantuvieron fijas las tasas de clasificación y el número de neuronas en la capa oculta, para así estimar

Tabla 2. Variación del método y sus resultados

MÉTODO	# Neuronas	Tasa entrenamiento	MSE	Épocas	Tasa Clasificación
Levenberg- MarquardtBackpropagation	15	0.1	0,0159	1000	0.3611
Gradient descent Backpropagation	15	0.1	0.169	1000	0.4306
Conjugate Gradient Backpropagation	15	0.1	0.120	1000	0.5576
One Step Secant	15	0.1	0.126	1000	0.5278

Fuente: elaboración propia.

el efecto de cada algoritmo de entrenamiento, como se muestra en la tabla 2.

Se puede apreciar que el método “ConjugateGradientBackpropagation” tuvo la tasa de clasificación más alta y menor error cuadrático medio.

Procedemos a continuación a exponer los resultados de los experimentos variando el número de neuronas empleadas en la capa oculta (tabla 3) y variando la tasa de entrenamiento (tabla 4), para ambos se utilizó el algoritmo de entrenamiento que mejor resultados arrojó de la prueba anterior.

Las tasas de clasificación más altas se obtuvieron usando unas cantidades entre 45 y 55 neuronas. Cuando se varió la tasa de entrenamiento se utilizaron 5 y 25 neuronas para observar los cambios.

Aunque las variaciones en las tasas de entrenamiento no produjeron resultados considerables, se muestran los resultados en la tabla 4.

Cabe resaltar que con 5 neuronas y una tasa de entrenamiento de 0.01 se obtuvo la mejor tasa de clasificación, siendo esta de 59.72 %.

Como alternativa para mejorar la tasa de clasificación y disminuir el error, implementamos el MLP mediante el uso de *Bi-clase*, los mejores resultados se obtuvieron realizando un barrido entre 5 y 20 neuronas cuyos resultados se muestran en la tabla 5.

A pesar de obtener errores cuadráticos medios, algo superiores, las tasas de clasificación mejoraron casi en un 20 %. Obteniendo la mejor clasificación (79,17%) con 10 neuronas y una tasa de clasificación de 0.1.

Tabla 3. Variando el número de neuronas en la capa oculta

# Neuronas	Tasa Entrenamiento	Épocas	Tasa Clasificación
5	0.1	1000	0.4306
10	0.1	1000	0.6111
15	0.1	1000	0.5556
25	0.1	1000	0.5556
35	0.1	1000	0.5278
45	0.1	1000	0.5972
5.5	0.1	1000	0.5694

Fuente: elaboración propia.

Tabla 4. Variando la tasa de entrenamiento

No. Neuronas	Tasa Entrenamiento	Épocas	Tasa Clasificación
5	0.001	1000	0.5000
5	0.01	1000	0.5972
5	0.02	1000	0.2222
5	0.2	1000	0.1944
25	0.01	1000	0.2222
25	0.05	1000	0.3194
25	0.1	1000	0.3889
25	0.5	1000	0.4444

Fuente: elaboración propia.

Tabla 5. Pruebas mediante clasificación *Bi-clase*

No. Neuronas	Tasa Entrenamiento	Error cuadrático	Épocas	Tasa Clasificación
5	0.1	0.173	1000	0.7639
10	0.1	0.192	1000	0.7917
20	0.1	0.0244	1000	0.7500
5	0.001	0.285	1000	0.7778
10	0.001	0.229	1000	0.7818

Fuente: elaboración propia.

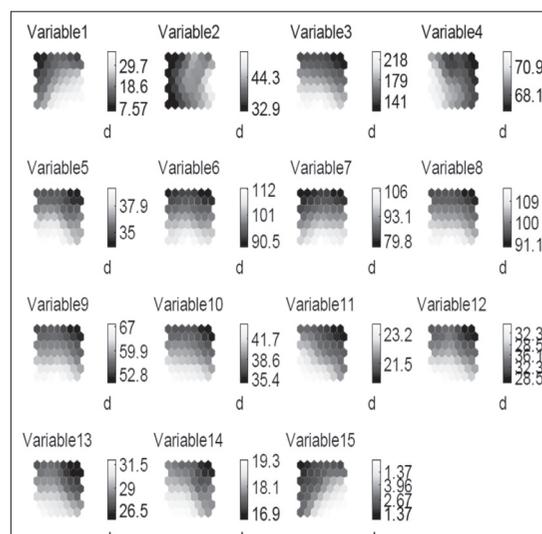
5.2. Estimación del porcentaje de grasa corporal implementado en SOM

Inicialmente presentamos cada una de las variables en un mapa elegido arbitrariamente, para ilustrar de manera muy superficial la información pertinente al efecto de cada variable en el mapa.

Se puede apreciar que cada uno de estos varía en rangos de valores muy distintos, y se hace necesaria una normalización de los datos para realizar el entrenamiento de la red SOM.

Algunos datos tienen rangos de unidades, así como otros comprenden valores de varias decenas. El tipo de inicialización no mostró un cambio considerable, los resultados mostraron una pequeña mejora en la respuesta de la red para la inicialización lineal (Tabla 6), es por esto que los experimentos restantes los realizamos fijando este parámetro.

Figura 4. Auto-organización de las variables en la red SOM



Fuente: SOM

Tabla 6. Prueba SOM variando el tipo de inicialización

Iniciación	Lineal	Randinit
Algoritmo	Seq	Seq
Normalización	Histc	Histc
Topología	10 x 10	10 x 10
Red	Hexa	Hexa
Media	0.6363	0.6315
Varianza	0.0022	0.0030

Fuente: elaboración propia.

A continuación realizamos un par de experimentos variando el tipo de normalización del algoritmo *Batch* y el algoritmo *Secuencial*, como se muestra en la tabla 7 y la tabla 8 respectivamente.

Las columnas subrayadas representan los experimentos que obtuvieron mejor resultado, estos serán empleados para la realización de los experimentos que siguen.

Se variará la cantidad de neuronas en el mapa en función del resultado obtenido de

Tabla 7. Prueba SOM variando el tipo de normalización para el algoritmo *Batch*

Iniciación	Lineal	Lineal	Lineal	Lineal	Lineal	Lineal
Algoritmo	Batch	Batch	Batch	Batch	Batch	Batch
Normalización	Histc	Var	Range	Log	Logistic	Histd
Topología	10 x 10	10 x 10	10 x 10	10 x 10	10 x 10	10 x 10
Red	Hexa	Hexa	Hexa	Hexa	Hexa	Hexa
Media	0.7183	0.6056	0.7746	0.5775	0.5070	0.7746
Varianza	0.0031	1,13e-27	1,13e-27	1,13e-27	1,13e-27	1,1e-27

Fuente: elaboración propia.

Tabla 8. Prueba SOM variando el tipo de normalización para el algoritmo secuencial

Iniciación	Lineal	Lineal	Lineal	Lineal	Lineal	Lineal
Algoritmo	Seq	Seq	Seq	Seq	Seq	Seq
Normalización	Histc	Var	Range	Log	Logistic	Histd
Topología	10 x 10	10 x 10				
Red	Hexa	Hexa	Hexa	Hexa	Hexa	Hexa
Media	0.6239	0.5811	0.7352	0.4904	0.5879	0.6628
Varianza	0.0030	0.0022	0.0035	0.0031	0.0029	0.00409

Fuente: elaboración propia.

Tabla 9. Prueba SOM variando el número de neuronas para el algoritmo *Batch* y red rectangular

Iniciación	Lineal	Lineal	Lineal	Lineal	Lineal
Algoritmo	Batch	Batch	Batch	Batch	Batch
Normalización	Range	Range	Range	Range	Range
Topología	10 x 10	9 x 9	8 x 8	7 x 7	8 x 5
Red	Rect	Rect	Rect	Rect	Rect
Media	0.7746	0.8169	0.8028	0.7746	0.7326
Varianza	1,13e-27	1,13e-27	1,13e-27	1,13e-27	0.0016

Fuente: elaboración propia.

Tabla 10. Prueba SOM variando el número de neuronas para el algoritmo *Batch* y red hexagonal

Iniciación	Lineal	Lineal	Lineal	Lineal	Lineal
Algoritmo	Batch	Batch	Batch	Batch	Batch
Normalización	Range	Range	Range	Range	Range
Topología	10 x 10	9 x 9	8 x 8	7 x 7	8 x 5
Red	Hexa	Hexa	Hexa	Hexa	Hexa
Media	0.7746	0.8028	0.8028	0.9014	0.8169
Varianza	1,13e-27	1,13e-27	1,13e-27	1,13e-27	0.0016

Fuente: elaboración propia.

Tabla 11. Prueba SOM variando el número de neuronas para el algoritmo secuencial y red rectangular

Iniciación	Lineal	Lineal	Lineal	Lineal	Lineal
Algoritmo	Seq	Seq	Seq	Seq	Seq
Normalización	Range	Range	Range	Range	Range
Topología	10 x 10	9 x 9	8 x 8	7 x 7	8 x 5
Red	Rect	Rect	Rect	Rect	Rect
Media	0.7352	0.7639	0.8073	0.8101	0.7501
Varianza	0.0035	0.0036	0.0015	0.0016	0.0016

Fuente: elaboración propia.

Tabla 12. Prueba SOM variando el número de neuronas para el algoritmo secuencial y red hexagonal

Iniciación	Lineal	Lineal	Lineal	Lineal	Lineal
Algoritmo	Seq	Seq	Seq	Seq	Seq
Normalización	Range	Range	Range	Range	Range
Topología	10 x 10	9 x 9	8 x 8	7 x 7	8 x 5
Red	Hexa	Hexa	Hexa	Hexa	Hexa
Media	0.7352	0.7352	0.8006	0.7989	0.7600
Varianza	0.0035	0.0030	0.0018	0.0022	0.0034

Fuente: elaboración propia.

la ecuación 1, esto se hará manteniendo fijo el algoritmo, en el primer caso será *Batch* para una red rectangular (tabla 9) y hexagonal (tabla 10). Y en el segundo caso será *Secuencial* (tablas 11 y 12).

6. Comparación y discusión

Para poder comparar los dos métodos, después de todas las pruebas realizadas, condensamos los mejores resultados obtenidos

en cada uno, para que se pueda observar mejor su desempeño.

En la tabla 13 se puede observar la comparación de los métodos usados a lo largo de este artículo, se puede, igualmente observar que para este problema en específico un entrenamiento mediante redes SOM arroja los mejores resultados.

Aunque la red neuronal MLP entrenada por el método *Biclase* arrojó buenos resultados,

Tabla 13. Mejores resultados de cada método

	MLP	MLP Bi-Clase	SOM
Tasa de Clasificación	59.72 %	79.17 %	90.14 %

Fuente: elaboración propia.

es un poco tediosa de programar y consume más recursos. Debido a esto es claro que la red SOM no solo arroja una buena tasa de clasificación, sino que también es eficiente en cuanto a recursos.

7. Conclusiones

Para el realizar una estimación del porcentaje de grasa corporal en hombres las redes SOM deben mostrar tasas de clasificación superiores a las proporcionadas por la red supervisada MLP como se ilustra en la tabla 13.

En bases de datos con valores tan cambiantes, con varianzas y medias muy distintas, es necesario seleccionar una normalización adecuada, pues esta es fundamental a la hora de realizar el entrenamiento como se observa en la tabla 7.

El uso de Redes neuronales no supervisadas usando mediciones de las circunferencias del cuerpo, puede llegar a representar un método económico, práctico y sencillo de implementar con un grado de confiabilidad muy alto.

8. Trabajos futuros

En un próximo trabajo se espera utilizar el mismo método de estimación y clasificación, usando sistemas difusos en vez de redes neuronales, con el fin de compararlos y analizar cuál es el que mejor se adapta a este problema en particular.

Además, se pretende extender el alcance de este trabajo incluyendo la estimación y clasificación para el porcentaje de grasa corporal en mujeres también.

9. Referencias

- [1] M. T. R.; Barbosa, Manuel R.; Amaral, Chouzal, Teresa María F. *Neural networks based approach to estimate body fat (%bf)*. Porto: Faculdade de Engenharia da Universidade do Porto. 2010.
- [2] D. R. A. N. Revathy. Neural network based regression model for accurate estimation of human body fat - obesity assessment using circumference measures. *International Journal of Computer and Network Security*. (2) 10. 2010.
- [3] Leite Pereira, Emilson & De Souza Filho, Carlos Roberto. Mapas auto-organizáveis aplicados a mapeamento do potencial mineral na região de serra leste, província mineral de Carajás. *Rev. Bras. Geof. [online]*, (28) 3. 2010,
- [4] Wehrens, Ron; Buydens, Lutgarde. Self- and Superorganizing Maps in R: The kohonenPackage. *Journal of Statistical Software*,(20) 5. October, 2007
- [5] Kuen-Chang Hsieh, Yu-Jen Chen, Hsueh-Kuan Lu, Ling- Chun Lee, Yong-Cheng Huang and Yu-Yawn Chen. The novel application of artificial neural network on bioelectrical impedance analysis to assess the body composition in elderly. *Hsieh et al. Nutrition Journal*. 2013.
- [6] X. R. Cui, M. F. Abbod, Q. Liu, Jiann-ShingShieh, T. Y. Chao, C. Y. Hsieh, Y. C. Yang. Ensembled artificial neural networks to predict the fitness score for body composition analysis. *The journal of nutrition, health & aging*, (15) 5, pp 341-348. May, 2011.
- [7] Khosravi, Abbas. SaeidNahavandi, Doug Creighton, & F.Atiya, Amir A comprehensive review of neural network-based prediction intervals and new advances. *IEEE Transactions On Neural Network*, December, 2010.
- [8] Jure Zupan. *Introduction to artificial neural network (ann) methods: what they are and how to use them*. Spain: Department of Chemistry, University Rovira i Virgili Tarragona. 1994.