

APROXIMACION GEOIDAL LOCAL USANDO UNA RED NEURONAL ARTIFICIAL MULTICAPA

ALFONSO TIERRA

Escuela Politécnica Del Ejército - ESPE
Centro de Investigaciones Espaciales - CIE
atierra@espe.edu.ec

RESUMEN – El creciente aumento de usuarios de tecnologías satélites, y en especial de los GNSS (Global Navigation satellite system) han hecho que se utilice para diferentes propósitos, tanto para fines científicos como para fines prácticos. En el caso, de los GPS (Global Positioning System), su uso es cada día mayor y en especial se quiere utilizar para algunos fines en ingeniería, en donde se requiere la altura de carácter físico con buena precisión. En vista que GPS proporciona alturas sobre una superficie geométrica, es necesario determinar un modelo geoidal para poder transformarla a la altura ortométrica. Modelos Geoidales actuales como es el EGM96 (Earth Geopotential Model, 1996) o el EGM08, es muy utilizado en la mayoría de los países, para pasar alturas elipsoidales a alturas ortométricas, pero en el Ecuador, y en áreas pequeñas, no se obtienen resultados satisfactorios para estudios de mayor precisión. Haciéndose necesario, que se conozca un modelo geoidal local, por lo que, se presenta otra forma de determinar valores de ondulaciones geoidales. Este método se basa en técnicas de aprendizaje mediante el entrenamiento de una red neuronal artificial – RNA. Son mostrados, los resultados obtenidos con el uso de un modelo matemático y con la técnica de RNA.

ABSTRACT - The growing increase number satellite technologies users, especially of the GNSS (Global Navigation Satellite System) have made to be used for different purposes, both for scientific and practical purposes. In the case, of GPS (Global Positioning System), its use is increasing and in particular we wanted to use for some purposes in engineering, which requires the physical character height with good accuracy. Given that GPS provides heights on a geometric surface, it is necessary to determine a geoid model, to transform it to the height orthometric. Actually, geoid models like the EGM96 (Earth Geopotential Model, 1996) or EGM08, is widely used in most of the countries, to transform to heights Orthometric to ellipsoidal heights. But in Ecuador, and in small areas, themselves not satisfactory results for studies of greater precision are obtained. Becoming necessary, as known geoid model local, so that presents another way to determine values of geoid undulations. This method is based in learning techniques him through training of a artificial neural network - RNA. They show the results achieved by using a mathematical model and the RNA technique

1 INTRODUCCION

El uso de los sistemas de navegación global por satélites artificiales – GNSS (Global Navigation Satellite System) cada día es mayor, y cada vez se utilizan en diferentes aplicaciones. En el caso, de obras de ingeniería, se necesita alturas de carácter físico como es la altura ortométrica (referida al Geoide). Pero cuando, se usa tecnología satelital, como es el GPS (Global Positioning System) se obtiene una altura de carácter geométrico conocida como altura elipsoidal. Creando de esta manera, la necesidad de transformar la altura geométrica a la altura ortométrica. Esta exigencia de obtener coordenadas con alta precisión tanto en horizontal, y principalmente en vertical par fines aplicativos, crea la necesidad de conocer el geoide con una alta precisión. Actualmente, se puede

usar modelos geopotenciales como el EGM96 (Leimone, et al., 1998), pero estos modelos en áreas locales no tienen una buena precisión, motivo por el cual es necesario conocer el geoide local y modelarlo usando diferentes métodos. Para un geoide local, es muy común modelarlo mediante aproximación de superficies usando técnicas de GPS y nivelación geométrica (Lima, et al. 2005), (Arana, 2000).

La ondulación geoidal (η) es obtenida por la diferencia entre la altura elipsoidal (h) (referida al elipsoide de referencia) y la altura ortométrica (H) (referida al geoide), y expresada de la forma siguiente:

$$\eta = h - H \quad (1)$$

En vista que, en la práctica la altura H , no es posible obtenerla actualmente, es usado la altura nivelada

(Hn) que es la distancia entre el nivel medio de los mares (definida por el datum vertical de la región) y el punto sobre la superficie terrestre. De esta forma, se puede obtener una ondulación de una forma aproximada de la siguiente manera:

$$\eta \cong h - H_n \quad (2)$$

2. AREA DE ESTUDIO

Para la realización de este estudio, se escogió un área aproximada de 490km² (25km x 20 km) ubicada dentro del Distrito Metropolitano de Quito, en la Provincia de Pichincha en Ecuador. La zona para este estudio se encuentra ubicada en altitudes que van desde los 2100 m a 2650 m.

Se obtuvieron un total de 257 puntos, en la cual cada punto disponía de coordenadas geodésicas (latitud, longitud y altura elipsoidal) referidas al WGS84, y obtenidas mediante campañas y procesamiento de datos GPS de alta precisión (Lima, 2005). De igual manera, en los mismos puntos se hizo nivelación geométrica, obteniendo la altura sobre el nivel medio de los mares a partir del datum vertical La Libertad (Lima, 2005).

De los 257 puntos, los 234 fueron usados para determinar la superficie de aproximación geoidal local, y los 23 restantes se usaron como puntos de control, con la finalidad de determinar las diferencias existentes entre el modelo obtenido comparado con los resultados de GPS y nivelación geométrica.

3. RED NEURONAL ARTIFICIAL MULTICAPA

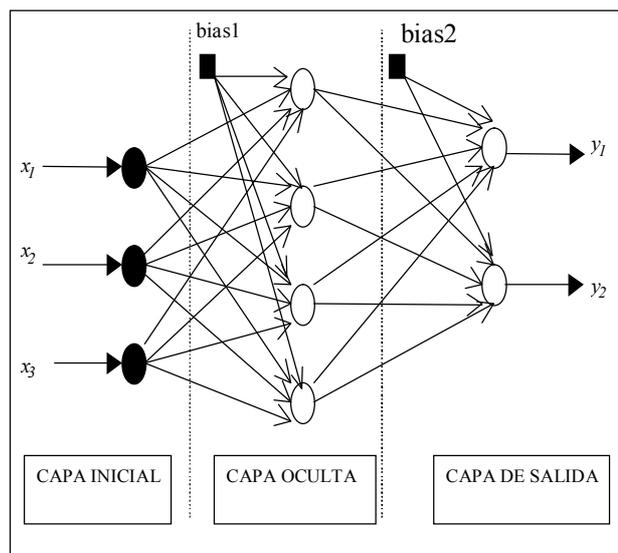
La RNA multicapa (RNAM) es una estructura que ha sido aplicada con mucho éxito en diferentes campos de la ciencia y de la ingeniería con el fin de resolver ciertos problemas que se tornaban difíciles con las metodologías conocidas, o que no se conseguían resultados satisfactorios. En el caso de modelamiento en áreas relacionadas con la geodesia, las RNAs han sido usadas en la transformación de sistemas de referencia (Tierra, et al., 2008), generación de mallas gravimétricas (Tierra, De Freitas, 2003), (Tierra, De Freitas, 2002). Ahora se aplica a la modelación de un geoide local con la finalidad de calcular ondulaciones geoidales.

La RNAM es una estructura que se encuentra organizada en capas y constituida por un conjunto de neuronas que están totalmente conectados entre sí. Las neuronas de una capa admiten como sus entradas, a las salidas de las neuronas de las capas anteriores, pero no admite que las neuronas de la misma capa se conecten entre sí.

El flujo de la información va hacia delante (feedforward) de capa en capa, comenzando en la capa inicial, conectándose con todas las neuronas, hasta llegar a la capa de salida. La estructura de la RNAM tiene una "alimentación progresiva hacia adelante". En este tipo de red no existe ningún tipo de conexiones entre las neuronas de la misma capa, ni con neuronas de las capas

anteriores, ya sea esta en forma directa o indirectamente. La figura 1, muestra una red del tipo feedforward con múltiples capas, conectadas hacia delante y cuya estructura esta conformada por: 3 vectores como entradas, en la capa inicial; 4 neuronas, en la única capa oculta; y 2 neuronas de salida, en la capa de salida. Los bias1 y bias2, están conectadas totalmente a las neuronas de la capa oculta y a las neuronas de la capa de salida, respectivamente.

Figura 1. Red Neuronal Artificial Multicapa (RNAM)



Una RNAM básicamente esta constituida por 3 capas, que son las siguientes:

La capa de entrada: formada por n unidades (siendo n el número de entradas externas), y su función es enviar las señales externas para la siguiente capa.

La capa oculta: esta formada por los elementos de procesamiento (EP) (Potukuchi & Wexler, 1997) (Gose et al., 1996), y no tiene contacto con el exterior. El número de capas ocultas es variable.

La capa de salida: esta formada por m elementos de procesamiento que son las salidas externas de la RNAM. Solo existe una capa de salida por cada RNAM.

3.1 Entrenamiento de la RNAM

Este tipo de red es entrenada mediante el algoritmo de aprendizaje conocido como *Retropropagación* (Backpropagation), que esta basado en la regla de aprendizaje por corrección del error (Haykin, 2001). La retropropagación es de tipo de aprendizaje supervisado, lo que significa que se debe disponer de datos de entrada, que servirán para el proceso de entrenamiento; y de datos de salida, que servirán para ir ajustando los pesos.

Básicamente este aprendizaje consiste en dos pasos:

- El primer paso, consiste en realizar la propagación de la señal de entrada hacia el

frente, neurona por neurona, capa por capa a través de la red, hasta llegar a la capa de salida. Durante la propagación, los pesos sinápticos son todos fijos. Cada EP de la capa oculta recibe las señales de la capa de entrada y se los agrega, este resultado es usado por la función de transferencia con el fin de generar una salida, y enviarla como entrada para las neuronas de la capa siguiente; esto es hecho, hasta la capa de salida.

- El segundo paso, consiste en realizar la retropropagación (es decir para atrás), durante este proceso, los pesos sinápticos son ajustados, de acuerdo con la regla de corrección del error, propagándose para atrás a través de la red, capa por capa, hasta la capa de entrada.

Estos pasos son realizados hasta que la red aprenda o alcance un buen desempeño, que es controlado mediante la utilización de un mecanismo de control conocido como de *error* (ϵ). Este error, en la capa de salida de la neurona j , es definido como la diferencia entre el valor deseado (d_j) con el valor calculado (y_j) por la red en el proceso feedforward, y dado por:

$$\epsilon_j = d_j - y_j \quad (3)$$

Este error, tiene como objetivo aplicar una secuencia de ajustes correctivos a los pesos sinápticos de la neurona j , con el fin de aproximar la señal de salida y_j de la respuesta deseada d_j . Este objetivo es alcanzado minimizando la función de costo, definido en función del error total de la red como:

$$MSE = \frac{1}{M} \sum_{j=1}^{mn} \epsilon_j^2 \quad (4)$$

donde:

mn es el número de neuronas en la capa de salida
 M es el número total de datos

El principal objetivo de la retropropagación es determinar cuales son los valores de los pesos y los *bias* que minimicen la función MSE, ajustando los pesos w_{ij} , de tal forma que, todos los vectores de entrada sea correctamente mapeados en las correspondientes salidas. Entonces, el proceso de aprendizaje puede ser visto como un problema de minimización de la función MSE definida en el espacio de los pesos W , esto es:

$$\frac{\partial MSE}{\partial w_{ij}} = 0 \quad (5)$$

donde w_{ij} indica el peso de la neurona j de la capa i .

Los pesos son actualizados y corregidos por un Δw_{ij} a partir de la última capa hasta la capa inicial. La

adaptación de los pesos es realizada en una forma iterativa de acuerdo con:

$$w_{ij}(n+1) = w_{ij}(n) + \Delta w_{ij}(n) \quad (6)$$

El índice n , significa el número de la iteración.

El proceso feedforward-retropropagación es realizado hasta que el número de épocas o iteraciones, que se informó al inicio del entrenamiento, haya concluido. Otra forma de identificar la convergencia del algoritmo es mediante el error de la salida alcanzado, si este error es menor o igual al error que se impuso al inicio del entrenamiento, entonces se dice que la red a terminado el entrenamiento.

Una vez que la red neuronal haya terminado su entrenamiento, ya se puede usar para predecir las salidas, a partir de otros valores en la entrada y que no intervinieron el proceso de aprendizaje.

4. PRUEBAS Y RESULTADOS

Lima (2005), determinó una superficie matemática que mejor se adaptó al geoide local. En ese estudio, el modelo que ajusto para el área de estudio, por el método de mínimos cuadrados, fue el siguiente:

$$\eta = aE + bN + cE^2 + dN^2 + e \quad (7)$$

Donde:

a, b, c, d, e son los parámetros

E, N son las coordenadas UTM, Este y Norte respectivamente

En este trabajo, se compara los resultados obtenidos por Lima (2005) y los obtenidos con la RNA entrenada. Para fines de comparación fueron escogidos los mismos 234 puntos para ejecutar el entrenamiento y los 23 puntos para evaluación de la RNA.

El proceso de entrenamiento de la RNA se realizó mediante el cambio de diferentes arquitecturas. En este caso, se utilizó una RNA Multicapa, y el aprendizaje supervisado fue el utilizado.

Los vectores de entrada en la capa de entrada fueron las coordenadas UTM referidas al elipsoide WGS84. En la capa oculta, se utilizaron diferentes funciones de transferencia, siendo la función tangente hiperbólica la que dio mejores resultados. En la capa de salida se usó la función de transferencia lineal, y el vector de salida fue la ondulación geoidal.

La figura 2, muestra el proceso de aprendizaje o entrenamiento que la RNA esta realizando hasta alcanzar el performance deseado por el supervisor.

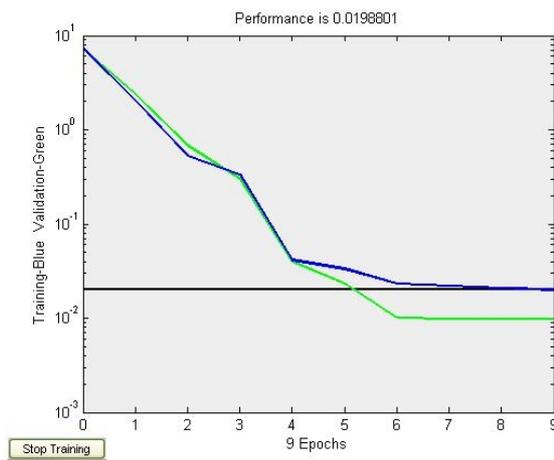


Figura 2 – Proceso de aprendizaje

La línea azul indica como la RNA va aprendiendo hasta alcanzar los resultados deseados, o hasta alcanzar el máximo conocimiento. La línea verde indica el error que comete la RNA en la predicción de los valores de ondulaciones geoidales comparados con los valores de los puntos de control. Cuando la línea azul llega a la meta deseada, se dice que fue entrenada, pero si la línea verde no alcanza esa meta, entonces a pesar que esta entrenada la RNA, su performance es bajo; es decir, los valores predichos, o en este caso, los valores de las ondulaciones geoidales tienen un error mayor de lo tolerado.

Después de las diferentes pruebas realizadas, en la cual se iban cambiando el número de neuronas en la capa oculta, la meta deseada, las funciones de transferencia, tanto en la capa oculta como en la de salida, se obtuvo la RNAM de mejor performance.

La figura 3, muestra la arquitectura final de la RNA entrenada, y es la que se utilizará para predecir valores de ondulaciones geoidales en el área de estudio de cualquier punto.

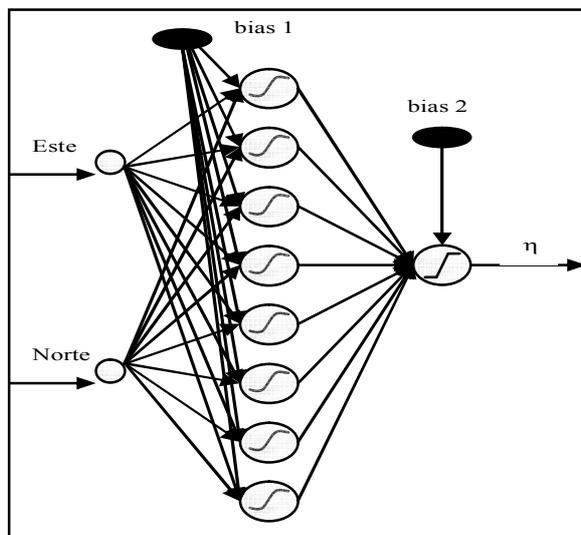


Figura 3 Red Neuronal Artificial [2 8 1]

En la figura 3, se puede observar: 2 vectores de entrada que son las coordenadas *Este y Norte*, en la capa de entrada; 8 neuronas en la capa oculta, con la función tangente hiperbólica; y una sola neurona en la capa de salida que es la ondulación geoidal (η) con la función de transferencia lineal.

Los resultados que fueron obtenidos, utilizando el modelo matemático de acuerdo a la ecuación (7), y los obtenidos mediante la predicción de ondulaciones geoidales utilizando la RNA Multicapa entrenada, fueron evaluadas con los mismos 23 puntos de control considerados como verdaderos.

Se determinaron las diferencias que existen entre las ondulaciones geoidales, calculadas con el modelo matemático y las obtenidas con GPS y nivelación. De la misma manera, se procedió a calcular las respectivas diferencias con los resultados de la RNA Multicapa y los puntos de control.

La tabla 1, muestra las diferencias entre los dos modelos en centímetros. En la primera columna se encuentra el número del punto de control; en la segunda columna, la diferencia de la ondulación geoidal en cm obtenido con el modelo matemático, y en la última columna, la diferencia obtenida con la predicción de la RNAM entrenada.

Tabla 1 – Diferencias en las ondulaciones geoidales.

Punto de evaluación	Diferencia con el modelo (cm)	Diferencia con la RNA (cm)
1	-0.5	0.7
2	12.6	-2.8
3	2.4	-0.9
4	6.2	-3.4
5	-2.9	1.7
6	5.1	-1.5
7	-1.0	-0.3
8	7.4	-4.5
9	6.1	-0.2
10	19.5	-4.9
11	0.5	-0.6
12	-0.9	-1.7
13	-1.2	0.8
14	-11.6	2.1
15	-3.2	1.5
16	-3.6	-1.8
17	-2.3	-1.0
18	3.4	-0.1
19	8.7	-1.8
20	1.5	-1.9
21	5.0	-2.9
22	-9.6	1.4
23	0.9	-4.7

Como puede ser observado en la tabla 1, los valores de las ondulaciones geoidales obtenidas con la RNA dan mejores resultados. Con la RNA se obtiene diferencias de hasta 5 cm, mientras que con el modelo se puede llegar a tener hasta 20 cm. También, se puede indicar que el 80 % de los puntos han mejorado los resultados.

En la tabla 2, se muestra los valores de la media aritmética, desviación estándar, el menor valor y el mayor valor de las diferencias obtenidas con los dos métodos.

Tabla 2. Estadísticas de las diferencias de los dos métodos

	Con el Modelo (cm)	Con la RNAM (cm)
Media	1.8	-1.2
Desviación estándar	6.8	2.1
Valor mínimo	-11.6	-4.9
Valor máximo	19.5	2.1

Observando los resultados de la tabla 2, se puede indicar que la desviación estándar ha mejorado más del 100%, y que además, los valores máximo y mínimo también son considerablemente menores.

La figura 4, muestra gráficamente las diferencias obtenidas en las ondulaciones geoidales con los dos métodos, y se puede observar la variabilidad que existe usando el modelo (cruz, en rojo) y usando la RNA (punto, en azul).

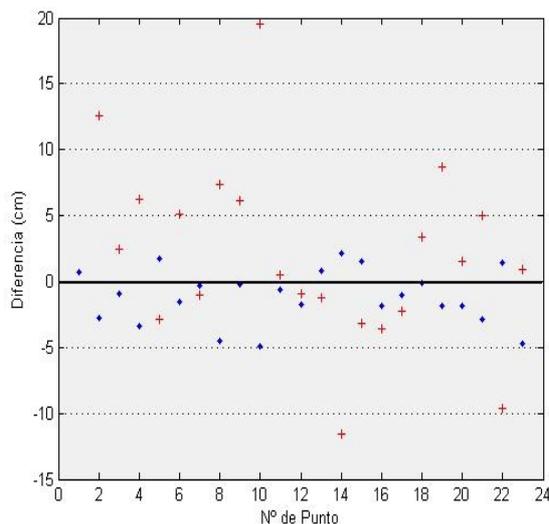


Figura 4 – Diferencias en las ondulaciones geoidales de los dos métodos.

5. CONCLUSIONES

Observando los resultados obtenidos con las dos metodologías usadas en este trabajo, se puede indicar lo siguiente:

- La técnica de RNA es muy útil para ser utilizado como aproximación de superficies ya que da mejores resultados que el ajuste de una superficie matemática para aproximar al geoido
- El uso de una RNA entrenada para interpolar ondulaciones geoidales se tiene buenas precisiones en el área de estudio.
- Los valores obtenidos, indica que este modelo neuronal puede servir para algunos trabajos en ingeniería, principalmente en actividades en donde el error en la altura ortométrica requerida, sea menor que los 5 cm.

REFERÊNCIAS

ARANA, J. o Uso do GPS na Elaboração de Carta Geoidal. Curitiba, UFPR, 2000, 138 p. Tesis de Doctorado.

GOSE, E. et.al. **Pattern Recognition and Image Analysis**. New Jersey, 1996.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2. ed. New Jersey: Prentice Hall, 2001.

LEMOINE, F. P. et al. **The Development of the Joint NASA GSFC and the National Imagery and Mapping Agency (NIMA) Geopotential Model EGM96**. NASA/TP-1998-206861, July 1998.

POTUKUCHI, S.; WEXLER, A. Predicting Vapor Pressures Using Neural Networks. **Atmospheric Environment**, Great Britain, v. 31, n. 4, p. 741-753, 1997

LIMA, P.; TIERRA, A.; ROBAYO, A. Determinación del Modelo Matemático para Obtener las Ondulaciones Geoidales en una Área del Distrito Metropolitano de Quito. **Revista Geoespacial**. N.2, p.33-48, 2005.

LIMA, P. Determinación del Modelo Matemático para Obtener las Ondulaciones Geoidales en una Área del Distrito Metropolitano de Quito. Sangolquí, ESPE, 2005, p. 152. Tesis de Grado de Ingeniero.

TIERRA, A.; DE FREITAS, S. Predicting Free-Air Gravity Anomaly Using Artificial Neural Network. **Vertical Reference Systems**, International Association of Geodesy Symposia. Springer, v. 124, p. 215-218, 2002.

TIERRA, A.; DE FREITAS, S. Predicción de Anomalías de Bouguer Mediante una Red Neuronal Artificial. **Revista Geofísica**. IPGH. México. V.59, p99-119, 2003

TIERRA, A.; DALAZOANA, R.; DE FREITAS, S. Using an Artificial Neural Network to Improve the Transformation of coordinates between classical geodetic reference frames. **Computers&Geosciences**, V.34, p.181-189, 2008.