

**EVALUACIÓN DE UNA METODOLOGÍA PARA LA GENERACIÓN DE
MODELOS DIGITALES DEL TERRENO A PARTIR DE
ESTEREOFOTOGRAMETRÍA DIGITAL APLICANDO EL MODELO DE
CORRELACIÓN POR MÍNIMOS CUADRADOS MEDIANTE UNA RED
NEURONAL ARTIFICIAL**



YEISON JAVIER CAJAMARCA MONTOYA

**UNIVERSIDAD DISTRITAL FRANCISCO JOSÉ DE CALDAS
FACULTAD DE INGENIERÍA
MAESTRÍA EN CIENCIAS DE LA INFORMACIÓN Y LAS COMUNICACIONES
BOGOTÁ; D.C.
2016**

**EVALUACIÓN DE UNA METODOLOGÍA PARA LA GENERACIÓN DE
MODELOS DIGITALES DEL TERRENO A PARTIR DE
ESTEREOFOTOGRAMETRÍA DIGITAL APLICANDO EL MODELO DE
CORRELACIÓN POR MÍNIMOS CUADRADOS MEDIANTE UNA RED
NEURONAL ARTIFICIAL**



YEISON JAVIER CAJAMARCA MONTOYA

20121295005

Trabajo de grado presentado en la modalidad de investigación

Director

Msc. William Barragán

UNIVERSIDAD DISTRITAL FRANCISCO JOSÉ DE CALDAS

FACULTAD DE INGENIERÍA

MAESTRÍA EN CIENCIAS DE LA INFORMACIÓN Y LAS COMUNICACIONES

BOGOTÁ; D.C.

2016



TABLA DE CONTENIDO

ÍNDICE DE IMÁGENES.....	3
ÍNDICE DE TABLAS.....	4
RESUMEN.....	5
ABSTRACT.....	6
1. INTRODUCCIÓN.....	7
2. OBJETIVOS.....	10
2.1. Objetivo General.....	10
2.2. Objetivos Específicos.....	10
3. MARCO TEÓRICO.....	11
3.1. Modelos Digitales del Terreno.....	11
3.2. Modelos de Correlación.....	12
3.2.1. Correspondencia o correlación por áreas (ABM).....	12
3.2.2. Correlación cruzada (Cross Correlation).....	16
3.2.3. Correlación por mínimos cuadrados.....	17
3.3. Redes neuronales artificiales (RNA).....	22
4. ESTADO DEL ARTE.....	25
4.1. Técnicas Para La Extracción De Modelos Digitales del Terreno.....	25
4.2. Métodos De Correlación En Imágenes Digitales.....	27
4.3. Técnicas De Correlación En Redes Neuronales Artificiales.....	32
5. HIPÓTESIS.....	34
6. METODOLOGÍA.....	35



6.1. Etapa de Conceptualización y Diseño	35
6.1.1 Documento de requerimientos	36
6.1.2 Diagrama de actividades	39
6.1.3 Casos de uso	42
6.1.4 Casos de uso expandidos.....	44
6.2 Etapa de desarrollo	47
6.2.1 Selección del patrón de búsqueda.....	48
6.2.2 Determinación del mecanismo de inferencia	49
6.2.3 Herramienta	50
6.3 Etapa de análisis de resultados.....	68
7. CONCLUSIONES Y RECOMENDACIONES	72
8. BIBLIOGRAFÍA	74
Anexo1	78
Anexo 2.....	81
Anexo 3.....	109



ÍNDICE DE IMÁGENES

Imagen 1 Ilustra el enfoque diferencial por mínimos cuadrados para la estimación del cambio de posición local.	20
Imagen 2 Modelo RNA.....	23
Imagen 3 Modelo en UML del procedimiento, diagrama de actividades.....	41
Imagen 4 Casos de uso	43
Imagen 5 Proceso general en la metodología	47
Imagen 6 Imágenes en la ventana de contenido del software Agisoft photoscan..	52
Imagen 7 Puntos homólogos detectados por el software para el proceso de correlación	53
Imagen 8 Modelo Digital de Elevación (MDE)	54
Imagen 9 Ortofoto del área de estudio con combinación RGB en verdadero color	56
Imagen 10 Imágenes con 10 y 5 clases.....	58
Imagen 11 Puntos capturados con los modelos estereoscópicos en zonas descubiertas.....	59
Imagen 12 Capas de insumo en el proceso.....	63
Imagen 13 Histogramas de las capas insumo del proceso.....	64
Imagen 14 Estructura básica de un archivo *.arff	65
Imagen 15 Modelo de RNA con una capa y 4 neuronas.....	66
Imagen 16 Modelo de RNA con dos capas y 12 neuronas	67
Imagen 17 Modelo de RNA con tres capas y 24 neuronas.....	67



ÍNDICE DE TABLAS

Tabla 1 Experimentos con cambio de numero de iteraciones con una capa de cuatro neuronas	68
Tabla 2 Experimentos con cambio de numero de iteraciones con dos capas y un total de 12 neuronas	69
Tabla 3 Experimentos con cambio de numero de iteraciones con tres capas y un total de 24 neuronas	70
Tabla 4 Datos obtenidos en el experimento con una capa y 4 neuronas.....	88
Tabla 5 Datos obtenidos en el experimento con dos capas y 12 neuronas	98
Tabla 6 Datos obtenidos en el experimento con tres capas y 24 neuronas.....	108



RESUMEN

Actualmente en el desarrollo de diferentes proyectos de gran magnitud, se hace necesario en el campo de la ingeniería y más específicamente en el área de la Geomática, la automatización de diversos procesos con altos niveles de precisión ya que de esto depende que se modelen todos los factores presentes en la zona de la forma más real posible. En este documento se hace un acercamiento general a tres temas fundamentales a trabajar en un proyecto cuyo objetivo general es evaluar una metodología para la elaboración de *modelos digitales del terreno* (MDT) introduciendo la teoría de *redes neuronales artificiales*¹ junto al modelo de correlación por *mínimos cuadrados*. El desarrollo de MDT's de alta precisión se convierte en un importante insumo cuando se van ejecutar proyectos de mitigación del riesgo por fenómenos naturales, en el ordenamiento territorial, en el comportamiento de cuencas hidrográficas y entre muchas otras áreas en donde conocer la topografía detallada de la zona a gran escala permite vislumbrar ciertas características que sirven de base para los análisis específicos en estas áreas especializadas.

¹ Son redes interconectadas masivamente en paralelo de elementos simples (usualmente adaptativos) y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico (Matich, 2001).



ABSTRACT

Nowadays on the development of a variety of huge projects is necessary in the engineering field, more specifically in the Geomatic field, automation of many processes with high accuracy levels because of that the modeling of all factors zone could be more realistic as possible. This document makes a general approach to three fundamental topics to work on a project which overall objective is to evaluate a methodology for digital terrain model (DTM) production adding the artificial neural network (ANN) theory by the least squares model correlation. The high accuracy DTM development becomes an important data input in the implementation of risk mitigation projects by natural phenomena either land use planning or watersheds behavior; and so on, there are many other knowledge fields that detailed land measure of the area in a large scales provides characteristics that are the basis for specific analyzes on each one.



1. INTRODUCCIÓN

Los *Modelos Digitales del Terreno* tienen una importante participación en varias áreas del conocimiento como apoyo en análisis realizados para obtener resultados más precisos. Con procesos estadísticos que permiten realizar procedimientos de interpolación global por regresión con el fin de determinar diferentes procesos naturales, se pueden modelar factores como precipitación, flujos hídricos, erosión, clima, entre otros (Sarría, 2006) y con ellos todos los procesos subsecuentes que pueden existir, entre estos varios relacionados con fenómenos que puedan afectar a la población presente en la zona. La metodología que se evalúa busca, a través de un modelo de RNA, determinar la validez de los resultados en el proceso de correlación por mínimos cuadrados para la obtención de MDT de alta precisión, que en un futuro y con un desarrollo completo, permitan tanto a instituciones públicas (DANE, INGEOMINAS, IDEAM, IGAC, entre otras) o privadas realizar análisis geográficos en donde la variable representada por estos modelos producidos garantice, junto a datos obtenidos de la misma calidad, simulaciones o modelamientos muy cercanos a la realidad del entorno objeto de estudio.

En la producción de MDT existen varias técnicas para su obtención como barrido laser aerotransportado, mediante interpolación de curvas de nivel de un mapa topográfico o con correlación automática de imágenes usando pares estereoscópicos de aerofotografías (Jancso & Melykuti, 2011), de la selección del método adecuado dependerá varios factores, entre ellos los tiempos de producción que se requieran para el proyecto, los recursos tecnológicos con los que se cuente y la información que se vaya a usar como insumo principal. En este caso se pretende avanzar en la generación de MDT's con base al efecto de estereoscopia que se consigue con la superposición de imágenes aéreas obtenidas de una misma área de estudio y el proceso de correlación subyacente que lo permite; dentro de las técnicas que se usan en este proceso de correlación, se usan aquellas que modelen estadísticamente el problema de manera semi-paramétrica y no paramétrica debido a la dificultad (en el análisis de imágenes) de



convertir matemáticamente la información implícita en una imagen digital a las descripciones y propiedades explícitas en el mundo físico (Geman & Gidas, 1991). Una de las técnicas que se ajusta a estos modelos estadísticos se conoce como correlación por *Mínimos Cuadrados*, una de las características que posee es su alta precisión la cual es inherente a la técnica, también cuenta con la capacidad de adaptabilidad frente a diferentes modos y variaciones del contenido de la imagen, estructura de la red, requerimientos de procesamiento y expectativas de precisión (Gruen A. , 2012). Teniendo en cuenta que el modelo obtenido mediante esta técnica presentara el problema denominado *obstrucción de la superficie del terreno* (Buitrago Aguilar, 1997), ya que normalmente el terreno se encuentra cubierto por elementos como construcciones, arboles, puentes y otros más que solo permiten una representación parcial del terreno, actualmente se usan líneas de forma y líneas de quiebre para ajustarlo a la morfología real y de esta forma eliminar la altura de estos; para atenuar este problema y teniendo en cuenta que se pretende evaluar una metodología que va a realizar estos análisis en grandes áreas con una cantidad considerable de información, se va a evaluar mediante un software especializado en minería de datos, que usa el mapa de clasificación de cobertura de la tierra generado; en la lógica del sistema se plantea el problema de tal forma que cuando identifica un valor radiométrico perteneciente a determinada cobertura, valida esta información en el mapa y realiza la operación necesaria para obtener la altura del punto, este mecanismo de inferencia se implementa aplicando la teoría de Redes Neuronales Artificiales RNA la cual sugiere la creación de redes neuronales compuestas por elementos (neuronas) operando en paralelo simulando la función biológica del cerebro humano, en donde la particularidad es que cada neurona es entrenada para operar cierta función cierto número de veces ajustando cada vez las conexiones entre las neuronas (pesos) y de esta forma generando resultados con base a los patrones aprendidos; esto permite obtener unos resultados más refinados en el proceso. Recientemente las RNA y en general la Inteligencia Computacional ha tenido un gran éxito como tecnología practica al incorporarse en las aplicaciones desarrolladas en diferentes campos del conocimiento, especialmente cuando estas aplicaciones tienen que ver con el reconocimiento de



patrones ya que logra modelar dentro de los fundamentos estadísticos de las redes neuronales los conceptos de la estadística convencional para reconocimiento de patrones (Bishop, 1995), en otras palabras, esta estadística convencional describe el modelo estadístico del problema. Finalmente para validar los datos obtenidos como la metodología propia de las RNA lo indica, se comparan con un pequeño porcentaje de datos procesados que no se haya incluido inicialmente en el proceso de aprendizaje en la red neuronal.



2. OBJETIVOS

2.1. Objetivo General

- Evaluación de una metodología para la obtención de modelos digitales del terreno (MDT) aplicando la teoría de redes neuronales artificiales utilizando el modelo de correlación por mínimos cuadrados.

2.2. Objetivos Específicos

- Identificar y determinar los requerimientos en la adaptación y comprobación de la metodología a ser evaluada en la obtención de los MDT tales como los casos de uso y demás recursos documentales preliminares al diseño.
- Definir el procedimiento mediante el cual se obtendrán los resultados esperados, esto a través de la definición del modelo de RNA y las herramientas (software) necesarias para evaluar la metodología.
- Construir, implementar y probar un modelo de RNA dentro de la metodología evaluada mediante un programa de escritorio, que con base en los resultados obtenidos permita determinar su validez.



3. MARCO TEÓRICO

3.1. Modelos Digitales del Terreno

El término *digital terrain model* tiene aparentemente su origen en el Laboratorio de fotogrametría del Instituto de Tecnología de Massachussetts en la década de los años 50 por Miller y Laflamme, quienes definen, "El modelo digital del terreno DTM es una simple representación estadística de la superficie continua de la tierra con una gran cantidad de puntos con sus coordenadas X, Y, Z conocidas dentro de un sistema de referencia arbitrario" (Li, Zhu, & Gold, 2004). En el trabajo se observan los principios del uso de los modelos digitales para el tratamiento de problemas tecnológicos, científicos y militares. El objeto de Miller y Laflamme fue acelerar el diseño de carreteras mediante el tratamiento digital de datos del terreno adquiridos por fotogrametría, planteándose una serie de algoritmos para la obtención de pendientes, áreas, etc. El problema del número de datos se planteó de forma crítica, dada la escasa capacidad de almacenamiento de los ordenadores en aquella época, y se propuso el uso de ecuaciones polinómicas para almacenar segmentos de los perfiles topográficos.

Al hablar de los MDT, se tiene que hacer referencia a ciertos procedimientos o tareas para su obtención y uso, inicialmente se pueden mencionar los procesos mediante los cuales puede ser posible su generación (El-Sheimy, Valeo, & Habib, 2005). Estos procesos van ligados a la precisión que se pretenda obtener en el modelo generado; ya que se puede trabajar con un modelo de elevación cuyo espaciamiento entre celdas sea de 1 grado y con una libertad de error amplia, o pasar por una precisión media con MDT obtenidos de información proveniente de satélites o digitalización de cartografía análoga, o a una precisión alta con modelos obtenidos a través de fotogrametría digital, imágenes de radar o levantamientos topográficos en campo; cada uno de estos siempre depende del presupuesto y la importancia del proyecto para su selección. La estructura de datos que normalmente se usa para la visualización de estos modelos es mediante una malla



rectangular o estructura matricial de elevación y mediante una *red irregular de triángulos* por sus siglas en inglés TIN, los dos siendo una representación de imágenes que usa modelos de puntos.

Ya con el MDT generado, este se puede modificar y ajustar según los criterios del usuario. Dentro de las modificaciones están ediciones posteriores para afinar el resultado en cuanto a su geometría; aplicación de filtros para suavizar y resaltar el modelo cuando sea necesario y también unir diferentes modelos siempre y cuando compartan el mismo sistema de referencia. En cuanto a la interpretación del modelo, este se puede realizar a dos niveles (El-Sheimy, Valeo, & Habib, 2005), geomorfometría general y geomorfometría específica, el primero relacionado con la pendiente y sus derivados, dentro de estos el gradiente y la orientación, y el segundo con aspectos específicos relacionados con el terreno y sus diferentes atributos, como por ejemplo un análisis hidrográfico en una cuenca específica. La visualización del modelo también es un procedimiento fundamental y en el cual se interactúa con el producto obtenido, en la visualización se puede explorar el producto y según los permisos que se tengan se podrá editar y modificar ciertas formas, en el caso que no, este cumplirá con un objetivo meramente informativo.

3.2. Modelos de Correlación

3.2.1. Correspondencia o correlación por áreas (*ABM²*)

La correlación por áreas se aplica a un par estereoscópico, formado por sus correspondientes imágenes izquierda y derecha, I_1 y I_2 respectivamente y las cuales están compuestas por un arreglo matricial de píxeles con sus diferentes niveles de gris. La idea de esta correlación es desplazar y posiblemente deformar una de las imágenes para que la intensidad de cada uno de sus píxeles, corresponda de la mejor forma con

² Area Based Matching



la intensidad de la otra imagen (Lang & Forstner, 1995). Normalmente la mejor correspondencia se consigue usando ya sea la medida de distancia o de similitud, expresión 2 y 1 respectivamente.

$$\max_T \left(\text{similitud}(I^1, T(I^2)) \right) \rightarrow \hat{T} \quad (EC. 1)$$

$$\min_T \left(\text{distancia}(I^1, T(I^2)) \right) \rightarrow \hat{T} \quad (EC. 2)$$

En el caso del análisis de un solo canal $g_k(z_i)$ ($k = 1, 2$, $z_i = (r_i, c_i)$) para cada imagen k , y siendo r, c las filas y columnas correspondientemente, se puede escribir el siguiente modelo, expresión 3:

$$(g' \doteq g_1, g'' \doteq g_2, \quad \text{etc.):}$$

$$g'(z'_i) = f(z'_i) + n'(z'_i)$$

$$g''(z''_i) = h(f(z'_i; p_G); p_I) + n''(z''_i) \quad (EC. 3)$$

Con la transformación geométrica paramétrica, expresión 4

$$T_G = f: \mathbb{R}^2 \rightarrow \mathbb{R}^2 \quad (EC. 4)$$



De esta forma dependiendo de los parámetros geométricos p_G y de la transformación de la intensidad, expresión 5

$$T_I = h: \mathbb{R} \rightarrow \mathbb{R} \quad (EC. 5)$$

Y de esta forma dependiendo de los parámetros radiométricos p_I .

Los componentes del modelo son los siguientes:

$f(z'_i) = f(r_i, c_i)$ Es la definición de una imagen

$g'(z'_i) = g_1(r_i, c_i)$ La primera imagen

$n'(z'_i) = n_1(r_i, c_i)$ El ruido de la primera imagen

$g''(z''_i) = g_2(p_i, q_i)$ La segunda imagen

$n''(z''_i) = n_2(p_i, q_i)$ El ruido de la segunda imagen

$T_G = f$ Es una transformación geométrica del sistema de coordenadas (r, c) de g_1 a el sistema de coordenadas (p, q) de g_2

p_G Son los parámetros de T_G

$T_I = h$ Es una transformación de intensidad, en general esta se refiere a los valores de I_1 a I_2

p_I Son los parámetros de T_I



Función de mapeo T_G

Esta función se refiere especialmente a la superficie o modelo generado. Ejemplo de estas transformaciones geométricas en las superficies generadas tienen que ver con la configuración normal de un estereomodelo, como:

- traslación en el plano horizontal
- traslación y rotación
- traslación, rotación y escala
- afinidad (para superficies planas localmente)
- proyección (para superficies planas a nivel global)
- suavizado (suavizado en las superficies sin oclusión)
- suavizado parcial (en zonas con oclusión)

La traslación es usada en la correlación cruzada (cross correlation) para la transferencia de puntos a una superficie demasiado plana; la afinidad es usada en la correlación por mínimos cuadrados para transferir puntos a una superficie plana suavizada localmente, y el suavizado parcial en correlación de múltiples puntos como por ejemplo imágenes SPOT.

Medida de similitud

Tiene que medirse que tan bien las dos imágenes se correlacionan, las medidas comúnmente usadas son:

- la suma de los productos
- la suma de los productos, reducido por la media (covarianza)
- la suma de las diferencias al cuadrado (mínimos cuadrados, L2 norm)
- la suma de las diferencias absolutas (L1 norm)
- correlación cruzada normalizada



Soluciones algorítmicas

Dentro de estas se pueden encontrar algoritmos:

- de búsqueda completa
- de búsqueda secuencial
- de búsqueda heurística
- mínimos cuadrados iterativos
- simples
- con programación dinámica

3.2.2. Correlación cruzada (Cross Correlation)

Esta es una técnica importante en el proceso de correlación entre dos imágenes digitales; se basa dos suposiciones:

1. Las dos imágenes difieren geométricamente solo de la traslación
2. Las dos imágenes difieren radiométricamente solo en el brillo y en el contraste

De esta forma la siguiente transformación

$$T_G: \begin{pmatrix} p \\ q \end{pmatrix}_i = \begin{pmatrix} r \\ c \end{pmatrix}_i - \begin{pmatrix} u \\ v \end{pmatrix} \quad (EC. 6)$$

Introduciendo los parámetros de cambio $p_G = (u, v)^T$; y para la transformación radiométrica se tiene la expresión 7:

$$T_I: h(f) = a + bf \quad (EC. 7)$$



Y también los valores estimados iniciales provienen de

$$\max_{u,v} \rho_{12}(u, v) \rightarrow (\hat{u}, \hat{v})^{(0)} \quad (EC. 8)$$

Normalmente el proceso de estimación funciona de manera de espiral, empezando la búsqueda desde un valor aproximado del valor de cambio, parando en el caso que encuentre el valor máximo de ρ_{12} .

En un proceso de búsqueda más afinado, se tiene el inicio de la correlación en la cima de una pirámide que está constituida por ventanas de 10 X 10 hasta 40 X40 pixeles. Inicialmente se determina la ventana en la imagen izquierda y se hace la búsqueda posterior en la imagen derecha; el valor estimado obtenido es transferido al proceso del siguiente nivel abajo y así hasta encontrar la ventana del nivel más bajo. Normalmente el valor de precisión estimado de esta técnica es de 1/3 (Lang & Forstner, 1995).

3.2.3. Correlación por mínimos cuadrados

Esta técnica es la generalización de la correlación cruzada, dentro de elementos destacados están:

1. Cualquier tipo de función de mapeo paramétrica puede ser asumida
2. Cualquier tipo de relación radiométrica paramétrica entre dos imágenes se puede manejar
3. El proceso de estimación es eficiente
4. Herramientas para la evaluación del proceso están disponibles



Inicialmente se debe mencionar el modelo de una dimensión con un único parámetro desconocido, el del cambio de posición, dado por las expresiones 9 y 10:

$$y = x - u \quad (\text{Ec. 9})$$

$$g(x_i) = f(y_i) + n(x_i), \quad i = 1, \dots, m \quad (\text{Ec. 10})$$

La señal $g(x_i)$ esta relacionada con la función $f(y_i)$ dada por un cambio de posición desconocido u . $n(x_i)$ Es el ruido que se pueda presentar y el número de mediciones denotado por m . Con un valor aproximado de u_0 se puede escribir la expresión 11:

$$u = u_0 + du \quad (\text{Ec. 11})$$

Donde du es la corrección al valor aproximado dado. De tal forma el modelo no lineal puede reescribirse como se indica en la expresión 12:

$$g(x_i) = f(x_i - u) + n(x_i)$$

$$g(x_i) = f(x_i - u_0 - du) + n(x_i) \quad (\text{Ec. 12})$$

Seguido se linealiza alrededor del punto $x_i - u_0$ para obtener la expresión 13:

$$g(x_i) = f(x_i - u_0) - f'(x_i - u_0)du + \frac{1}{2}f''(x_i - u_0 - \zeta du)du^2 + n(x_i) \quad (\text{Ec. 13})$$



Para $\zeta \in [0,1]$ y donde $f'(y) = df/dy$ y $f''(y) = d^2f/dy^2$ (Ec. 14)

A continuación se asume que f' no desaparece y los terminos de segundo orden son insignificantes.

Con las diferencias

$$\Delta g(x_i) = g(x_i) - f(x_i - u_0)$$

Y derivando

$$f'_i = f'(x_i - u_0)$$

Se obtiene el modelo linealizado de la expresión 15

$$\Delta g(x_i) = -f'_i du + n(x_i), \quad i = 1, \dots, m \quad (\text{Ec. 15})$$

O explícitamente en la expresión 16

$$g(x_i) - f(x_i - u_0) = \frac{df(y)}{dy} \Big|_{y=x_i-u_0} du + n(x_i), \quad i = 1, \dots, m \quad (\text{Ec. 16})$$



Dada la solución para la única medición de $g(x_i)$, ósea $m = 1$

$$\widehat{du}_i = -\frac{\Delta g(x_i)}{f'_i} \Big|_{y=x_i-u_0}$$

Se tiene

$$\widehat{u}_i = u_0 + \widehat{du}_i \quad (\text{Ec. 17})$$

En donde se estima que el cambio local en la intensidad es causada por un cambio de posición desconocido (Lang & Forstner, 1995) como se observa en la imagen 1.

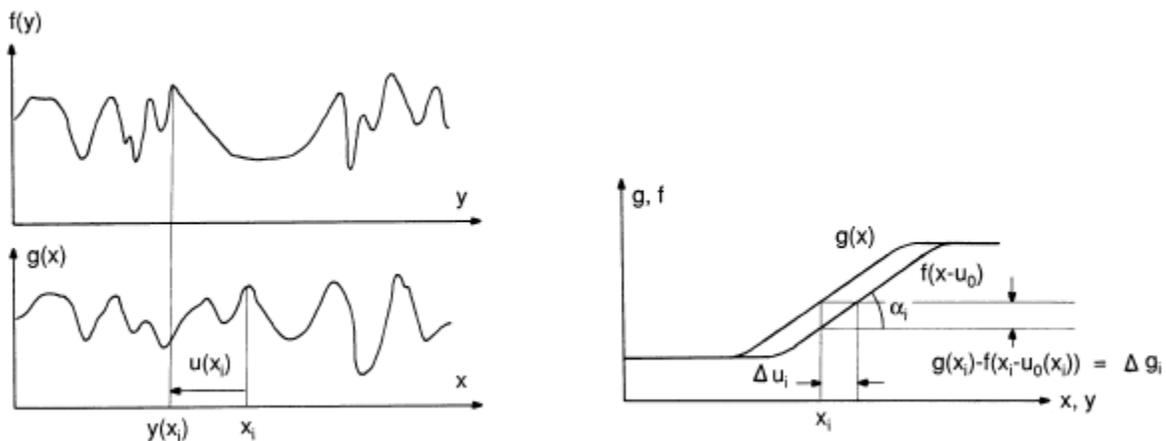


Imagen 1 Ilustra el enfoque diferencial por mínimos cuadrados para la estimación del cambio de posición local, fuente (Lang & Forstner, 1995).

Teniendo claro el modelo presentando anteriormente, ahora se puede abordar el problema con los parámetros geométricos T_G y los de intensidad o radiométricos T_I .

Explícitamente las mediciones lineales pueden definirse como lo indica la expresión 18 y 19 a continuación (Lang & Forstner, 1995):

$$T_G: \begin{pmatrix} p \\ q \end{pmatrix} = \begin{pmatrix} a_1 & a_2 \\ a_4 & a_5 \end{pmatrix} \begin{pmatrix} r \\ c \end{pmatrix}_i + \begin{pmatrix} a_3 \\ a_6 \end{pmatrix} \quad (\text{Ec. 18})$$

$$T_I: h(f) = a_7 \cdot f + a_8 \quad (\text{Ec. 19})$$



Usando los siguientes valores iniciales

$$a_{0k} = 1, \quad k = 1,5,7$$

$$a_{0k} = 0, \quad k = 2,3,4,6,8$$

Se obtiene las ecuaciones para las mediciones m , ecuación 20:

$$\Delta g(x_i) = f_{ri} \cdot r_i \cdot \widehat{d\hat{a}}_1 + f_{ri} \cdot c_i \cdot \widehat{d\hat{a}}_2 + f_{ri} \cdot \widehat{d\hat{a}}_3 + f_{ci} \cdot r_i \cdot \widehat{d\hat{a}}_4 + f_{ci} \cdot c_i \cdot \widehat{d\hat{a}}_5 + f_{ci} \cdot \widehat{d\hat{a}}_6 + f_i \cdot \widehat{d\hat{a}}_7 + 1 \cdot \widehat{d\hat{a}}_8 + n(x_i) \quad (\text{Ec. 20})$$

Con

$$\begin{pmatrix} p \\ q \end{pmatrix}_{0i} = \begin{pmatrix} a_{01} & a_{02} \\ a_{04} & a_{05} \end{pmatrix} \begin{pmatrix} r \\ c \end{pmatrix}_i + \begin{pmatrix} a_{03} \\ a_{06} \end{pmatrix}$$

$$\widehat{d\hat{a}}_k = \hat{a}_k - a_{0k}$$

$$\Delta g(x_i) = g_2(r_i, c_i) - g_1(p_{0i}, q_{0i})$$

$$\bar{n}_i = n_2(r_i, c_i) - n_1(p_{0i}, q_{0i})$$

Estimando

$$f_{ri} = \frac{\partial \hat{g}_1(r_i, c_i)}{\partial r}$$

$$f_{ci} = \frac{\partial \hat{g}_1(r_i, c_i)}{\partial c}$$

$$f_i = \hat{g}_1(r_i, c_i)$$

Donde \hat{g}_1 es un restaurado de g_1 , por ejemplo, la versión suavizada del resultado inicial.



3.3. Redes neuronales artificiales (RNA)

Cuando se usa el término de RNA se debe hacer referencia a modelos de programación que pretenden emular las funciones biológicas del cerebro humano a través del desarrollo de algoritmos de aprendizaje. En la actualidad los computadores realizan operaciones de tipo secuencial, lo que quiere decir una operación a la vez; todo lo contrario con el funcionamiento del cerebro humano que opera de manera *no-lineal* y paralela. Dentro de las ventajas en el desarrollo de RNA en proyectos para la solución de determinados problemas están, la capacidad de adquirir el conocimiento y almacenarlo de manera similar al cerebro, a la vez que asigna cierto peso relativo en las conexiones interneuronales, fundamental en el proceso de toma de decisión. También cabe anotar la alta resistencia y recuperación a fallas en el funcionamiento (Izaurieta & Saavedra).

En el manejo de imágenes digitales las RNA han tenido una gran relevancia en cuanto a modelos de clasificación y reconocimiento de patrones; normalmente en la estadística de reconocimiento de patrones al igual que las RNA se manejan unas funciones matemáticas que contienen cierto número de parámetros cuyos valores son determinados con la ayuda de los datos capturados. Estas funciones se puede escribir de la siguiente manera (Bishop, 1995):

$$y_k = y_k(X; W) \quad (Ec. 21)$$

Donde W es el vector de parámetros normalmente llamados pesos. Una RNA es básicamente la selección de una de estas funciones $y_k(X; W)$, basando su importancia en el marco general que ofrece para representar problemas *no-lineales*, recibiendo ciertas variables de entrada y dando otras de salida, en donde la función solución es sujeta a modificaciones en sus parámetros según sea el caso. El proceso en el que se



determinan los valores de los parámetros es llamado *entrenamiento* o *aprendizaje* de la RNA.

A continuación en la imagen 2 se puede observar el modelo básico en una red neuronal

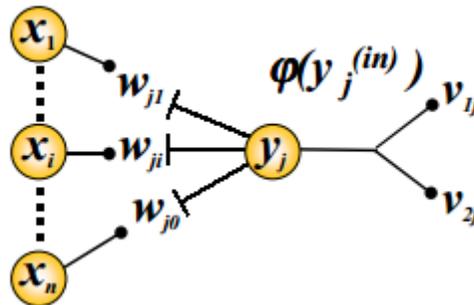


Imagen 2 Modelo RNA, fuente (Izaurieta & Saavedra)

Donde las neuronas X están enviando señales de entrada, normalmente valores numéricos; w corresponde a los pesos y básicamente se multiplica por la entrada correspondiente para darle de esta forma la importancia relativa dentro del modelo definido. φ corresponde a la función de activación, por ejemplo la tipo escalón o sigmoideal.

La distribución de neuronas dentro de la red se realiza formando niveles o capas, con un número determinado de dichas neuronas en cada una de ellas. A partir de su situación dentro de la red, se pueden distinguir tres tipos de capas:

- *De entrada*: es la capa que recibe directamente la información proveniente de las fuentes externas de la red.
- *Ocultas*: son internas a la red y no tienen contacto directo con el entorno exterior. El número de niveles ocultos puede estar entre cero y un número elevado. Las neuronas de las capas ocultas pueden estar interconectadas de distintas



maneras, lo que determina, junto con su número, las distintas topologías de redes neuronales.

- *De salidas*: transfieren información de la red hacia el exterior.



4. ESTADO DEL ARTE

4.1. Técnicas Para La Extracción De Modelos Digitales del Terreno

Actualmente existen tres tipos de técnicas indirectas para la obtención de un modelo digital del terreno de manera automática (Maune, 2011), por métodos *estereofotogrametría digital*, por *Interferometría de Radar de Apertura Sintética* o por *Detección y alcance de luz o mejor conocido* por su acrónimo en inglés *LIDAR*; entre los modelos obtenidos de manera manual se puede nombrar otro método (Jancso & Melykuti, 2011) que consiste en la obtención del modelo por medio de la interpolación de elementos geométricos obtenidos de una cartografía digital como por ejemplo curvas de nivel, vías, superficies de agua, entre otros; se considera manual ya que los elementos han sido definidos por un operador en base al modelo estereoscópico.

La *estereofotogrametría* permite obtener una cartografía en 3D con base en los datos obtenidos con imágenes en 2D aplicando los conceptos de estereoscopia sobre un par de fotografías en las cuales exista cubrimiento de la misma zona de interés desde dos diferentes perspectivas; en ocasiones se puede llegar a obtener una precisión entre intervalos de curvas de nivel menor a 15 cm, permitiendo determinar la ubicación relativa de puntos, líneas y áreas, útiles para la determinación de distancias, ángulos, volúmenes, alturas, tamaños y formas de elementos cartográficos (Maune, 2011). Actualmente este método es altamente usado para representar los elementos asociados a áreas urbanas como construcciones, urbanizaciones, vías, etc. En las áreas de planeación, arquitectura, telecomunicaciones, turismo, entre otras, permite realizar simulaciones en donde aplicando estos datos se pueden realizar actividades como el planeamiento, análisis y visualización de los diferentes escenarios que se puedan presentar (El Garouani, Alobeid, & El Garouani, 2014); en el proyecto referenciado se puede observar la metodología que se siguió para elaborar la cartografía digital en 3D de la ciudad de Fez en Marruecos, donde se elaboró un MDS para representar las construcciones presentes



en la ciudad. Para acercarse a la obtención de un MDT con esta metodología se requiere la consideración de otras fuentes de información para su elaboración debido a que existen elementos superficiales que no dejan observar la altura real del terreno, estos como construcciones, vegetación, viaductos, etc. En (Sohn & Dowman, 2007) se observa como la combinación de dos fuentes de información permiten obtener resultados con mayor grado de precisión, en este proyecto se planteó una metodología mediante la cual se obtienen las construcciones presentes en el área urbana con el uso de datos IKONOS y LiDAR del municipio de Greenwich en la ciudad de Londres; la fusión de estos datos permitió suplir en cierto grado las fallas propias de cada uno, por un lado la falta de continuidad de ciertos elementos que describen las construcciones por obstrucciones o por deficiencias en la calidad de la imagen y por otro lado el espacio sin información que queda entre pulso y pulso con la técnica LiDAR. Básicamente la metodología usa las imágenes IKONOS para identificar las zonas urbanas por sus diferentes características, entre las más importantes la textura y el color de los elementos, en base a esto identifica las líneas o polígonos que describen estas estructuras que adicionalmente con los datos LiDAR que le aportan la altura correspondiente permiten generar el modelo en 3D y en donde se obtuvo una precisión satisfactoria. En (Nurminen, Karjalainen, Yu, Hyypä, & Honkavaara, 2013) se hace el análisis del inventario forestal presente en la ciudad de Sonkajärvi en Finlandia Central, en este proyecto se cuenta con estereofotografías con solape del 60% y 80% de las cuales se obtiene la información correspondiente a la altura de la copa de los árboles, por otro lado cuentan con datos LiDAR de donde se obtiene la altura del terreno; en base a estos datos se obtiene el volumen de la biomasa presente en determinadas parcelas objeto de estudio. Inicialmente se realizan los cálculos con los modelos con el 60% de solape y posteriormente con el 80% con el ánimo de analizar su inferencia en el resultado final, obteniendo valores similares; en base a este artículo lo importante es hacer un especial énfasis a la versatilidad con la que cuentan las imágenes aéreas por su alta resolución espectral ya que a esta información van ligadas ciertas características que pueden describir mejor el elemento presente en la imagen (en este caso la tonalidad de la copa del árbol). Una mayor aproximación al objeto del proyecto se puede observar en (Zhou, Song, Simmers, & Cheng, 2004), donde se generan varios



modelos urbanos en 3D de Wytheville, Virginia; entre ellos un MDT obtenido de datos LiDAR, de donde se obtiene la altura de los puntos por la nube de datos obtenida y posteriormente con las imágenes pancromáticas se identifican las construcciones por su tonalidad; teniendo estos datos proceden a eliminar los datos de altura en estas áreas y con ayuda de una interpolación automática se obtiene la altura del terreno en el área construida. Es claro que en la generación automática de MDT el método de selección depende de las características propias del proyecto y los objetivos que en él se planteen, si se opta por tecnologías de *Interferometría de Radar de Apertura Sintética o LiDAR*, estas acarrearán con sigilo un gran costo en su producción llevando esto normalmente a la adquisición de metodologías más económicas relacionadas con la *estereofotogrametría digital* (Maune, 2011) (Jancso & Melykuti, 2011).

4.2. Métodos De Correlación En Imágenes Digitales

La correlación de imágenes ha venido siendo uno de los principales temas de investigación en el campo de la fotogrametría digital y visión computarizada por muchos años, aplicándose en diferentes campos y con diversos enfoques (Gruen A. , 2012). Por lo general estos problemas son de corte no paramétrico o semi-paramétrico por tanto necesitan información y suposiciones a priori del entorno a modelar ósea información independiente de los datos y de las ecuaciones de las imágenes (Geman & Gidas, 1991). En cuanto a la correlación de imágenes digitales, el proceso consiste en la identificación automática de los puntos homólogos en un par de imágenes (Lizana, 2008). Básicamente existen tres técnicas de correlación (Gruen A. , 2012), *basada en la intensidad, basada en elementos y relaciona*. En la técnica basada en la intensidad se utilizan los datos originales de la imagen en forma de una matriz de valores de grises; la técnica basada en elementos requiere que se extraigan unos elementos básicos de la imagen, como uniones, bordes, áreas, entre otros para con esta información proceder a correlacionar los elementos entre sí (CHONG, GAY, NGEETAN, & LIU, 2000). En algunas ocasiones



los elementos son más estables que los píxeles con respecto a sus niveles de reflectancia (Gruen A. , 2012), (Cai, Zhou, Li, & Zhuang, 2005); una de las ventajas de esta técnica es la precisión al localizar las discontinuidades de profundidad y alturas estimadas en escenas urbanas complejas (McKeown & Hsieh, 1992), en (Adjouadi & Candocia, 1994) se puede ver como con el uso de la transformada de *Walsh* dentro de un algoritmo de correlación aporta diversos niveles precisión en los resultados obtenidos ya que al cambiar el tamaño del *kernel* de la transformada, puede aportar mayor o menor información en el proceso de emparejamiento; la tercera técnica denominada correlación relacional (*Relational matching*) (Gruen A. , 2012), consiste en usar relaciones geométricas u otras relaciones entre los elementos y estructuras del modelo (combinación de elementos), la correspondencia es establecida mediante técnicas de árboles de decisión; estos métodos no son muy precisos pero si robustos. Esta técnica es usada para la generación de MDT pero su generación es más bien escasa. A continuación se referencian algunos proyectos como en (Harlyn Baker, 1982) donde se observa cómo se aplican los dos primeros métodos mencionados para generar un modelo en tres dimensiones de una zona urbana; inicialmente mediante elementos, contornos o bordes (*edges*) se identifican las principales discontinuidades en la escena y posteriormente se usan estos elementos (líneas) obtenidos como límites para generar ciertas áreas en donde utilizando el método basado en la correlación cruzada (*cross-correlation*) se obtiene el resultado propuesto. Se puede observar como en (Jiang, Xie, & Pan, 2014) se plantean los aspectos que actualmente son relevantes en cuanto a la precisión en la correlación de imágenes digitales, ya que se asevera que actualmente los estudios van encaminados a generar técnicas de correlación más robustas que a la evaluación del error, de esta misma manera la demanda de la información en tiempo real y de alta calidad también se convierten en un importante requerimiento, consecuentemente se puede observar el uso del método de correlación cruzada en la técnica denominada *imagen integral* también conocida como *tabla de área sumada*, la cual fue usada para acelerar el computo del algoritmo sin sacrificar la precisión de medida; esta técnica es altamente aplicable cuando la suma de los valores en una región rectangular es frecuentemente consultada. Sin embargo (Gruen A. W., 1985) afirma que



este método es bueno y rápido siempre que las muestras a ser correlacionadas contengan una señal suficiente sin muchos valores altos en la frecuencia y las distorsiones radiométricas y geométricas se mantengan al mínimo, características que difícilmente se encuentran en las imágenes aéreas; atendiendo estas dificultades el autor desarrollo una técnica denominada *Adaptive Least Squares Correlation*, en donde el algoritmo se basa en el método de mínimos cuadrados por su flexibilidad y potencia para realizar la correlación de los datos particularmente la correlación de imágenes; en el nombre se introdujo la palabra adaptado por el manejo de varios parámetros en el proceso, entre ellos la orientación y la geometría que pueden afectar los datos en el resultado obtenido. El método de correlación por *mínimos cuadrados (least squares matching)* que también es llamado *basado en área (area-based matching)* (Gruen A. , 2012) está dentro de los métodos prominentes en la técnica basada en la intensidad. Este es el más antiguo y simple método utilizado en algoritmos de estéreo correlación (Hannah, 1988).

En (Lee, Kim, Park, & Lee, 2003) se sigue apreciando como a partir de un barrido de imágenes SPOT pancromáticas y mediante el efecto estereoscópico entre dos imágenes se obtuvo el modelo digital de elevación con dos técnicas de correlación, la primera en base a la línea epipolar, también llamada correlación de búsqueda en una dimensión, la cual consiste la obtención de los puntos sobre esta línea, que coincide con la línea de barrido, pero presentando inconsistencias en los puntos que no coincidan con esta; para mejorar la calidad del modelo posteriormente se realiza la correlación mediante mínimos cuadrados, o correlación de búsqueda en dos dimensiones, en donde la relación de los puntos entre las dos imágenes es conocida como una *transformación afín*, en donde a través de los bucles del algoritmo de estimación por mínimos cuadrados se actualizan los parámetros de la transformación y consecuentemente se obtienen resultados más precisos. Otro ejemplo en donde la combinación de técnicas de correlación permite obtener mejores resultados se observa en (Hsieh, Perlant, & McKeown, 1990), en donde usan el *método de diferencias* dentro de la técnica de *mínimos cuadrados (basada en área)* para desarrollar un algoritmo cuyo objetivo es obtener unos datos del modelo



específicos (Áreas abiertas con variedad de construcciones dispersas); el procedimiento se realiza a nivel de ventana de búsqueda, de manera que entre mayor o menor tamaño de la ventana en la secuencia de iteraciones, se irán recalculando los valores de disparidad en base a las diferencias detectadas, teniendo en cuenta que los primeros valores de disparidad calculados no cuentan con una buena precisión. Seguido a esto se desarrolla otro algoritmo cuya técnica *basada en elementos* permitirá obtener otros datos del modelo específicos (Áreas consolidadas con alta concentración de construcciones); esta técnica usa un método que se basa en la geometría epipolar, ya que a través de estas líneas, evalúa los valores de reluctancia y calcula con los elementos (features) a correlacionar el valor correcto de disparidad; por último se hace una fusión de los resultados obtenidos presentando valores de precisión aceptables. En (McKeown & Hsieh, 1992) se describe detalladamente la técnica de correlación basada en elementos mencionada anteriormente en donde se realizaron varios experimentos con variaciones en el terreno tales como forma de las construcciones, tamaño y altura.

En (Muller, Mandanayake, Moroney, Davies, Diner, & Paradise, 2002) se observa una metodología para crear modelos de elevación de la superficie de las nubes en base a datos obtenidos del *Espectro-radiómetro de imágenes de multi-ángulo (Multi-angle Imaging SpectroRadiometer MISR)*, que es un dispositivo de un satélite lanzado por la NASA en diciembre de 1999, el cual produce imágenes en la banda del rojo con una resolución de 275 m a través de una franja con ancho de 360 km para los nueve ángulos de captura que posee; los autores crean un algoritmo de correlación basado en elementos llamado *Nested Maxima Stereo-Matcher (NM)* para la detección rápida de un pequeño grupo de elementos candidatos para la correlación, al mismo tiempo se crean los algoritmos basados en intensidad *Multipoint Matcher Using Means* y *Multipoint Matcher Using Medians*, los cuales operan posterior al NM y aportan una mejor precisión a la hora de seleccionar los elementos candidatos debido a la precisión por-píxel que maneja; los resultados obtenidos son comparados con los obtenidos a partir de un algoritmo llamando *Pyramidal Gruen–Otto–Chau Adaptive Least Squares Correlation (P-Gotcha)*, de la *University College London* el cual es altamente apoyado en la teoría del



ajuste por mínimos cuadrados, este algoritmo se seleccionó para la comparación por el autor debido a la agudeza a nivel de sub-píxel (típicamente 0.3 píxeles), la capacidad para predecir una precisión estimada en base al valor propio de la matriz de varianza-covarianza y también debido a su característica de robustez frente a errores.

Hasta este punto se puede observar que en esta línea de investigación se siguen desarrollando metodologías orientadas a obtener datos más precisos a partir del proceso de correlación a pesar de los problemas que se puedan encontrar en el análisis de las imágenes digitales, tales como desplazamientos, ruidos, etc.; adicionalmente puede verse como el proceso de correlación de imágenes digitales por mínimos cuadrados puede usarse de diferentes modos y variaciones. En el marco algorítmico, este método es altamente adaptativo a varios tipos de contenidos de imágenes, estructuras de red, requerimientos de procesamiento y altas expectativas de precisión. En el pasado se ha demostrado que este método permite la explotación del máximo de precisión en cuanto a sistemas e imágenes, permite una precisión de medida más alta que la obtenida a través de las capacidades de un operador humano (Gruen A. , 2012).



4.3. Técnicas De Correlación En Redes Neuronales Artificiales

Actualmente la Inteligencia Computacional (IC) y específicamente la teoría de las RNA ha sido incursionada en el tratamiento de imágenes digitales en aplicaciones cuyo problema sea el de reconocimiento de patrones (Bishop, 1995); consecuentemente en el campo de la geomatica se ha venido usando esta nueva tecnología para adaptarla a diferentes procesos y con resultados traducidos en software en el mercado con diferentes módulos de clasificación de imágenes con estas características. Un primer acercamiento de teorías de IC en la correlación de imágenes se puede ver en (Cai, Zhou, Li, & Zhuang, 2005) en donde en el desarrollo de un algoritmo de correlación se introduce la *teoría difusa*, que resuelve los problemas de falta de certeza en el proceso de correlación; con el propósito de obtener precisión en la correspondencia de los pixeles, allí se introduce el principio de *distorsión de tiempo dinámico (dynamic time warping)* el cual también es usado en aplicaciones para el reconocimiento de voces.

Según (Gallo, Binaghi, & Raspanti, 2008), los problemas correlación se acoplan bien al cálculo computacional con redes neuronales. La inclusión de las RNA en la aplicación de técnicas de correlación ha sido trabajo de investigación con el fin de observar el potencial de adaptación del aprendizaje neuronal. En la fotogrametría terrestre las RNA se han venido trabajando en varios proyectos relacionados con la correlación de imágenes digitales para obtener modelos en tres dimensiones, esto se puede ver en (Binaghi, Gallo, Marino, & Raspanti, 2004) en donde evalúan la aplicación de un modelo de red neuronal en la generación del mapa de valores de disparidad a partir de unas imágenes de prueba de un proyecto de referencia, este mismo modelo de red se aplica a un grupo de datos provenientes de imágenes obtenidas del *scanning electron microscope* para aplicaciones en el campo de la Biomedicina; en este proyecto el autor propone un novedoso método basado en el coeficiente de correlación cruzada *Zero Mean Normalized* dentro de un modelo de red neuronal que usa la *regla delta* o de *mínimos cuadrados* para el entrenamiento, en este caso el aprendizaje de la red es formulado como la búsqueda de la ventana apropiada en tamaño y forma para cada



región candidata a ser correlacionada. En (Zhong, Peng, Zhong, & Dong, 2012) proponen un método robusto de agregación neuronal para el cálculo de mapas de valores de disparidad, en donde el pre proceso es generado con datos las bandas RGB de las imágenes y con el método *normalizado de correlación cruzada (normalized cross-correlation)* para estimar un primer mapa de disparidad; posteriormente con la inclusión de método de agregación neuronal se usa una de red de dos capas en donde una de ellas es oculta y es definida por una función Gaussiana, y donde al final todos los valores de salida son sumados para formar el valor de disparidad. Básicamente el proceso que se llevó a cabo en el análisis de las imágenes, empezó desde la descomposición de las imágenes en cada uno de sus filtros, su posterior correlación y obtención de valores de disparidad y la agregación de la red neuronal para la obtención de los resultados más precisos



5. HIPÓTESIS

La introducción de la teoría de las RNA (cuya capacidad de aprendizaje adaptativo permite realizar tareas basadas en un entrenamiento o en una experiencia inicial) en la evaluación de una metodología para la generación de MDT, considera su adaptación a través de los requerimientos específicos del proceso, logrando definir este de tal forma que se identifica cuantitativamente el nivel de correlación de las variables que intervienen y consecuentemente su relevancia o no en el resultado final.



6. METODOLOGÍA

En este proyecto de tipo investigativo aplicado se hace uso del método de investigación sistémico, ya que los MDT son resultado de la determinación de los valores de cada uno de los puntos en el espacio que se pretenda hacer el análisis, esto con el fin de obtener una visualización en tres dimensiones a partir de la relación entre ellos.

La metodología que se desarrolla en el proyecto para su adecuado control y seguimiento, está compuesta por tres etapas:

- I. Etapa de conceptualización y diseño
- II. Etapa de desarrollo
- III. Etapa de análisis de resultados

6.1. Etapa de Conceptualización y Diseño

Inicialmente en esta etapa se establecen los requisitos y restricciones que en el modelo evaluado se deben tener en cuenta para su construcción y correcto funcionamiento con el fin de darle solución al problema inicialmente planteado. Esta actividad es fundamental ya que facilita la delimitación del proyecto y define las funcionalidades que se obtienen del sistema así como los resultados de manera clara.

Se debe tener presente que de no especificar las funcionalidades correctamente se pueden presentar retrasos en el desarrollo de proyecto, ya que al obtener resultados inválidos en las etapas finales, se supone una corrección de fallas en las etapas previas y muchas veces en las iniciales.

Para garantizar la claridad en las funciones del sistema, se genera un documento basándose en la plantilla del IEEE (*The Institute of Electrical and Electronics Engineers*,



Inc) para los SRS (*Software Requirements Specification*), la cual se compone de tres partes: la primera en donde se describe el proyecto que se pretende desarrollar, una segunda parte en donde se especifica el nombre del usuario, y la última parte que describe los requerimientos funcionales del sistema. A continuación se puede apreciar el documento de requerimientos elaborado.

6.1.1 Documento de requerimientos

Evaluación de una metodología para la generación de modelos digitales del terreno a partir de estereofotogrametría digital aplicando el modelo de correlación por mínimos cuadrados mediante una red neuronal artificial

Usuario: **Usuario experto**

Requerimientos Funcionales:

- **Cálculo del valor de disparidad para cada uno de los puntos sujetos al proceso de correlación.**
- **En el cálculo del valor de la altura de cada punto se tiene en cuenta el nivel digital y su relación con el mapa de clasificación de coberturas.**
- **En la generación del modelo en tres dimensiones de cada par estereoscópico, se empalma con cada uno de los modelos de los pares contiguos, esto para eliminar la información redundante y garantizar su consistencia.**
- **Se genera un Modelo Digital de Elevación en base a los cálculos previos.**



- La información obtenida previamente se aplica a un modelo de red neuronal con el fin de aprovechar su característica de auto aprendizaje para emular el proceso realizado por un operador humano.
- Cálculo del valor de la precisión del modelo basándose en los valores residuales obtenidos en el proceso de experimentación con el número de iteraciones definido.

Requerimientos No Funcionales:

- Las actividades las realizarán usuarios expertos, es decir, usuarios que comprenden el proceso de generación de MDT, al igual que el manejo o minería de datos.
- La estructura del sistema está modelada en UML
- El proceso se desarrolla utilizando programas de uso libre (open source) y privativo.
- El equipo en el cual se desarrolla el proyecto es una laptop HP envy-14 con Disco duro de 1 TB, memoria RAM de 8 GB y procesador Intel-core i5.
- Los resultados del proyecto se entregan en el segundo semestre de 2016.

Glosario:

Disparidad: dada la posición de los ojos en los humanos y la forma de moverlos las imágenes que se reciben en cada ojo son prácticamente iguales, con una diferencia en la posición relativa de los objetos. Estas diferencias relativas en la posición en cada imagen, se denomina *disparidad*, y tiene una relación directa con la distancia (profundidad) a la que se encuentran los objetos entre sí, y al observador. El cerebro es capaz de interpretar esa diferencia y reconstruir la estructura de la escena que ve el observador (Lecumberry).



Correlación: grado de semejanza entre los niveles digitales de dos pixeles homólogos en un par estereoscópico.

Nivel digital: valor numérico que cuantifica la radiancia recibida por el sensor en determinada banda del espectro electromagnético.

Cobertura del suelo: unidad delimitable que surge a partir de un análisis de respuestas espectrales determinadas por sus características fisionómicas y ambientales, diferenciables con respecto a la unidad próxima.

Modelo Digital del Terreno (MDT): es una representación estadística de la superficie continua del terreno, mediante un número elevado de puntos selectos con coordenadas x, y, z conocidas, en un sistema de coordenadas arbitrario.

UML: Es un lenguaje de modelado unificado, que permite especificar, visualizar y documentar modelos en sistemas de software, es una de las especificaciones de la *OMG (The Object Management Group™)* más usadas, no solo para modelar la estructura de aplicaciones, funcionamiento y arquitectura sino también procesos de negocios y estructuras de datos. Por ser un lenguaje estándar, permite programar de manera versátil mediante códigos, muchos modelos de funcionamiento de cualquier compañía o empresa, con la seguridad de recibir excelentes resultados según sean las necesidades del usuario; esto significa productividad para la empresa o entidad.

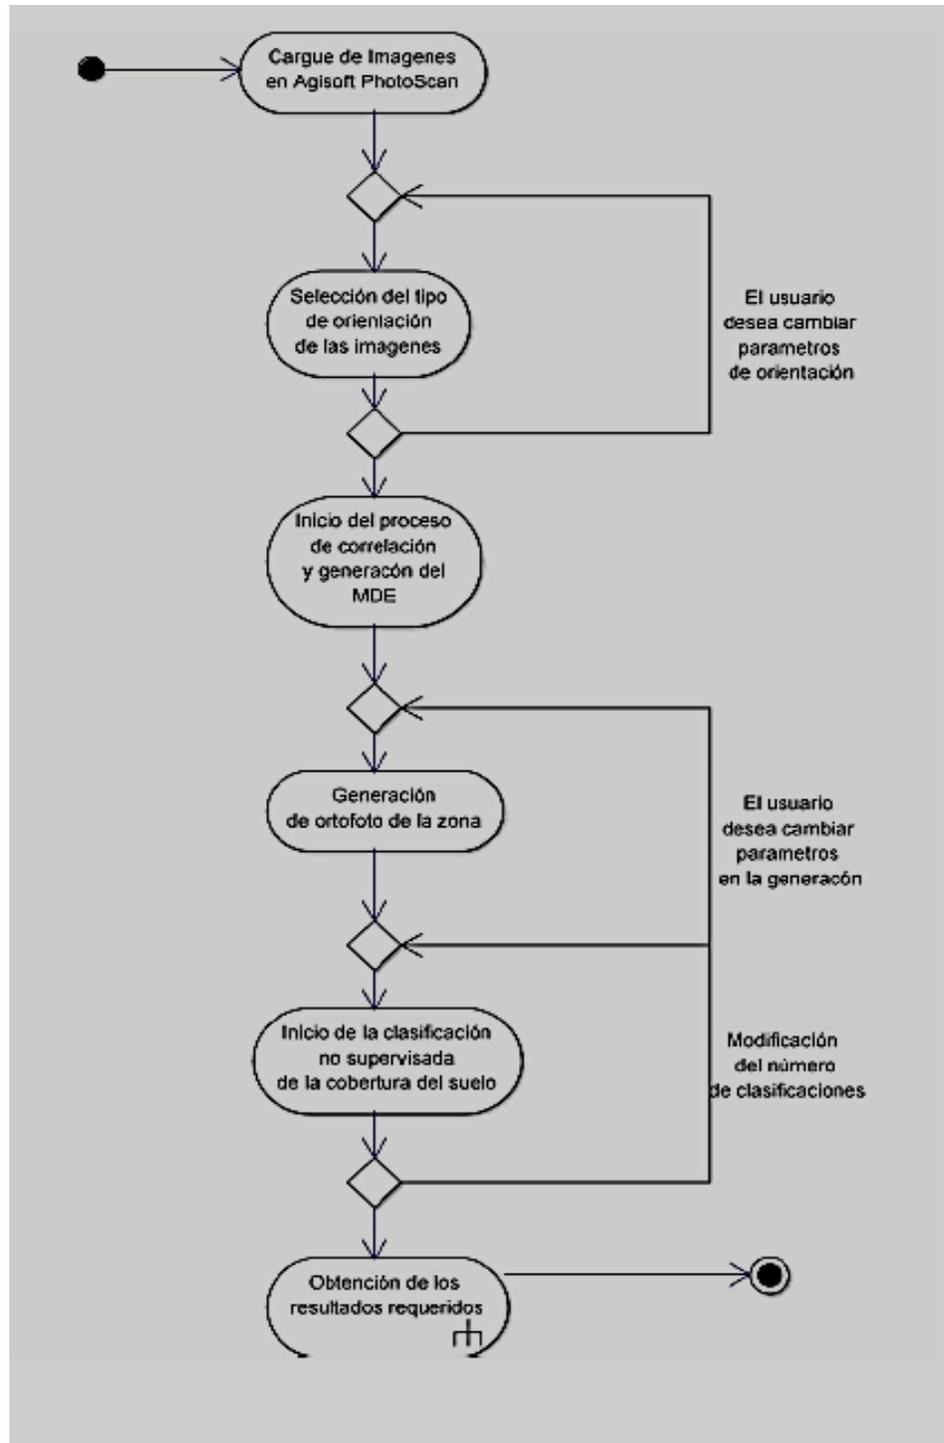


6.1.2 Diagrama de actividades

Seguido a este documento de requerimientos, se procede a desarrollar el diagrama de actividades, que hace referencia a las relaciones y secuencia de los procedimientos que existen en el proyecto; normalmente este tipo de representaciones o diagramas pretende explicar las interacciones y asociaciones de las actividades a los usuarios y los lectores especializados, esto mediante el uso del lenguaje estándar de modelado UML³.

A continuación en la imagen 3 se puede observar el diagrama de actividades en el procedimiento:

³ UML sirve para el modelado completo de sistemas complejos, tanto en el diseño de los sistemas software como para la arquitectura hardware donde se ejecuten. (Hernandez Orallo)



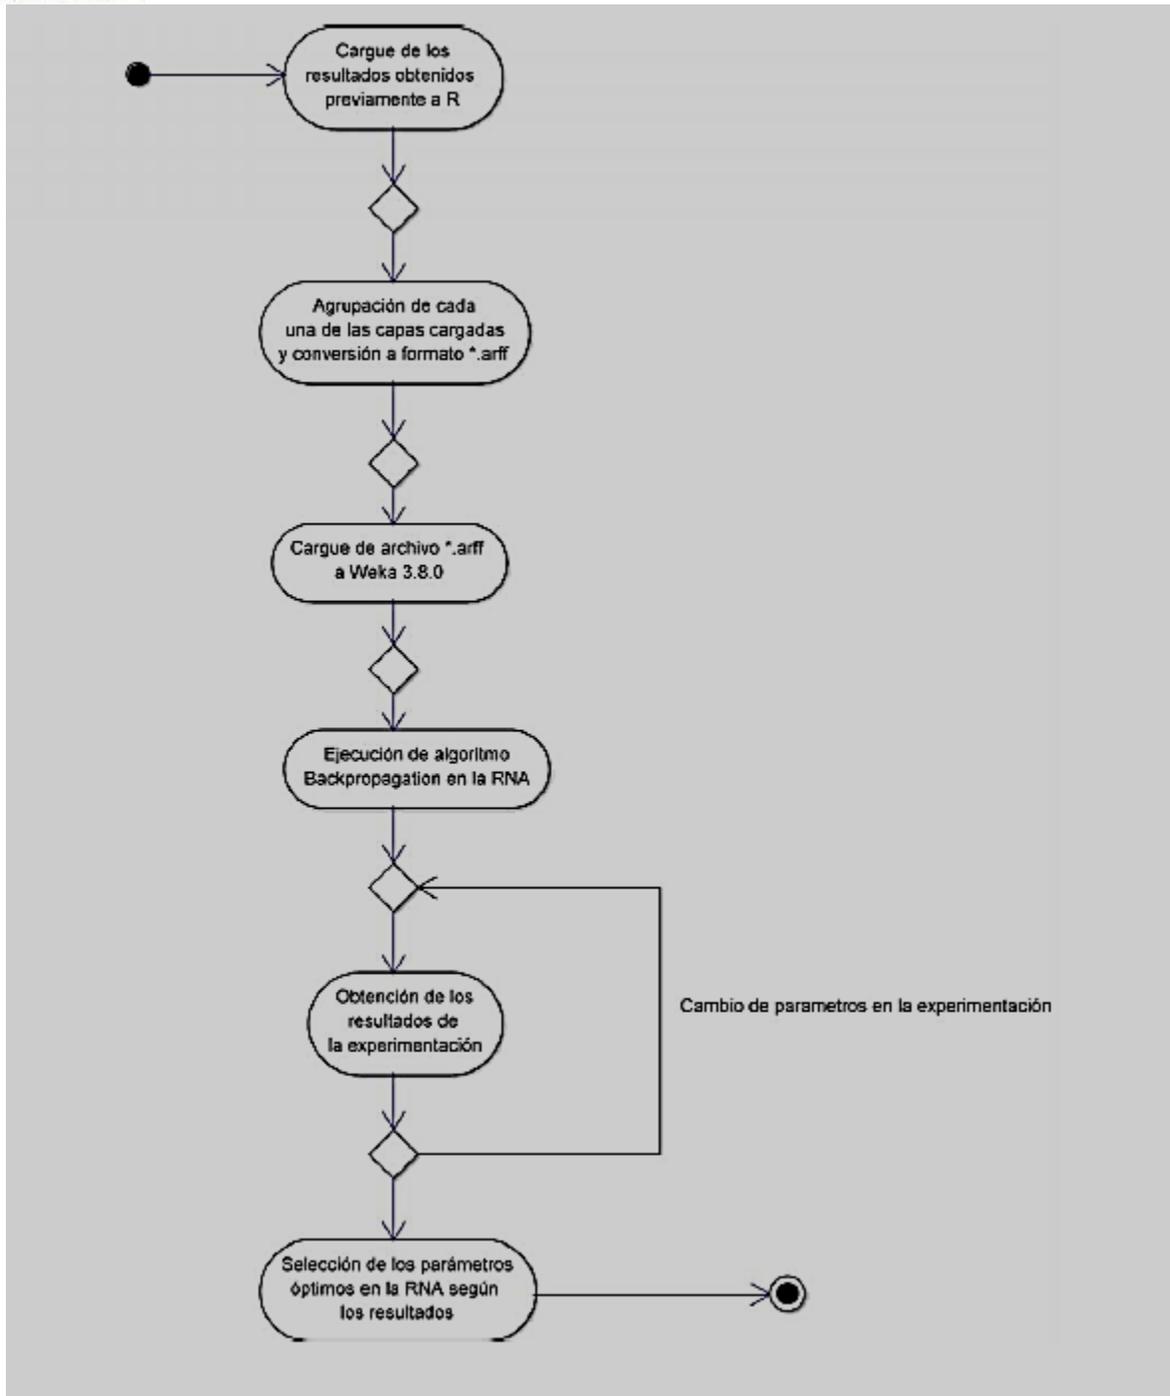


Imagen 3 Modelo en UML del procedimiento, diagrama de actividades, fuente (Autor)



6.1.3 Casos de uso

Los diagramas de casos de uso describen las interacciones que existen entre los usuarios y el sistema dentro de un ambiente que comúnmente se resume en las peticiones y posteriores respuestas que se pretenden ejecutar en este; en resumen, un caso de uso cuenta la historia de los actores al usar el sistema.

"...Un caso de uso es una secuencia de acciones que un sistema ejecuta y que llevan a un resultado observable de valor para un actor en particular" (Larman, 2005).

Para interpretar correctamente los casos de uso se deben tener claros algunos conceptos como: **Actores** que representan cualquier objeto que tiene relación con el sistema y **Casos de Uso**, los cuales se representan en forma de elipses y describen las funciones del sistema; el mismo caso de uso que se emplea para la fase de requerimientos se usa en las etapas siguientes del proyecto (desarrollo y análisis de resultados).

A continuación en la imagen 4, se presenta el diagrama de casos de uso que se elabora para el proyecto:

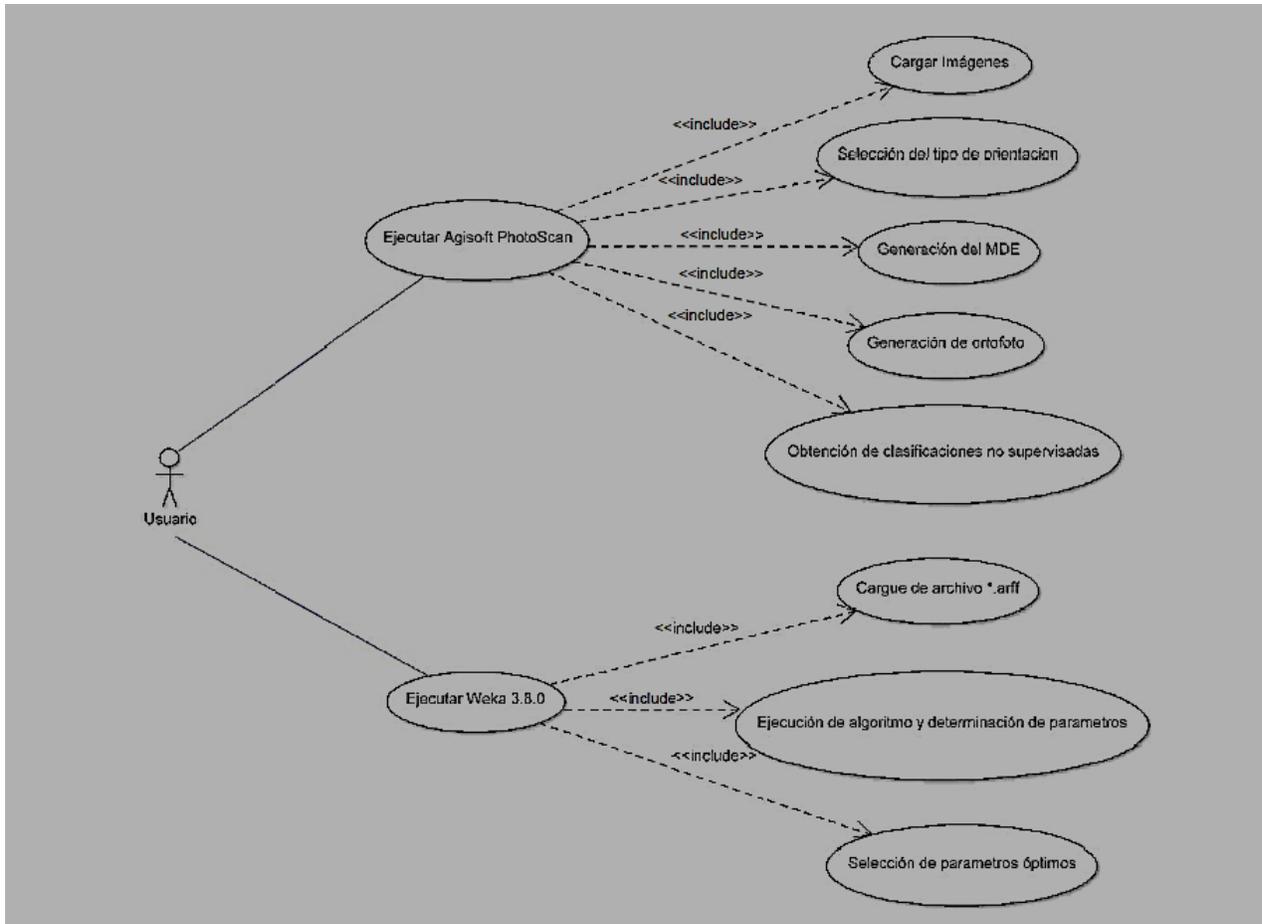


Imagen 4 Casos de uso, fuente (Autor)



6.1.4 Casos de uso expandidos

Caso de Uso -1: Ejecutar Agisoft PhotoScan

Alcance: **El proceso bajo diseño**

Nivel: **EBP⁴**

Actor Primario: **Usuario**

Precondiciones: **El usuario habrá accedido a la interface de escritorio.**

Flujo de eventos primarios:

1. El usuario carga la información que sirve como insumo para la generación del MDE.
2. El software permite seleccionar y modificar los parámetros que intervienen en el proceso de correlación y generación de del MDE.
3. El software genera una ortofoto con ayuda del MDE obtenido previamente.
4. El software permite realizar clasificaciones no supervisadas de las diferentes coberturas presentes.

⁴ Elementary Business Process



Extensiones:

De la calidad de las imágenes insumo del proceso (resolución radiométrica, espacial, temporal) dependerá el resultado obtenido.

Al no contar con la información espacial exacta de la zona a trabajar, el software permite realizar el proceso asignando un sistema de referencia arbitrario.

El resultado que se pretenda obtener debe ser coherente con las características técnicas del equipo de cómputo utilizado, ya que dependiendo de los parámetros seleccionados, estos pueden llevar a un alto grado de procesamiento los componentes de la máquina.



Caso de Uso -2: Ejecutar Weka 3.8.0

Alcance: **El proceso bajo diseño**

Nivel: **EBP**

Actor Primario: **Usuario**

Precondiciones: **El usuario habrá accedido a la interface de escritorio.**

Flujo de eventos primarios:

1. **El usuario carga la información que sirve como insumo en la RNA.**
2. **El software permite seleccionar el algoritmo de correlación y modificar los parámetros que intervienen en el proceso de aprendizaje de la RNA.**
3. **El usuario oprime el botón "start".**
4. **El software ejecuta los procedimientos lógicos implementados en el aplicativo mediante la función *Multilayer Perceptron* .**
5. **El software genera un archivo con la información procesada.**
6. **El software genera un reporte con el resumen del procedimiento realizado con los valores estadísticos correspondientes.**
7. **Según los resultados obtenidos, el usuario selecciona la mejor combinación de valores asociados a este (taza de aprendizaje, iteraciones, momentum).**



Extensiones:

Según el número de nodos y capas seleccionadas en el diseño de la RNA el tiempo del proceso varía.

6.2 Etapa de desarrollo

En esta etapa se materializa el procedimiento, que de manera general consiste en seleccionar el modelo estereoscópico para someterlo al proceso de correlación y posteriormente su resultado es agregado en una red neuronal artificial, la cual mediante parámetros de aprendizaje logra obtener el valor de correlación global con todas las variables que intervienen y el error obtenido del modelo digital del terreno de la zona, véase el procedimiento de manera general en la imagen 6.

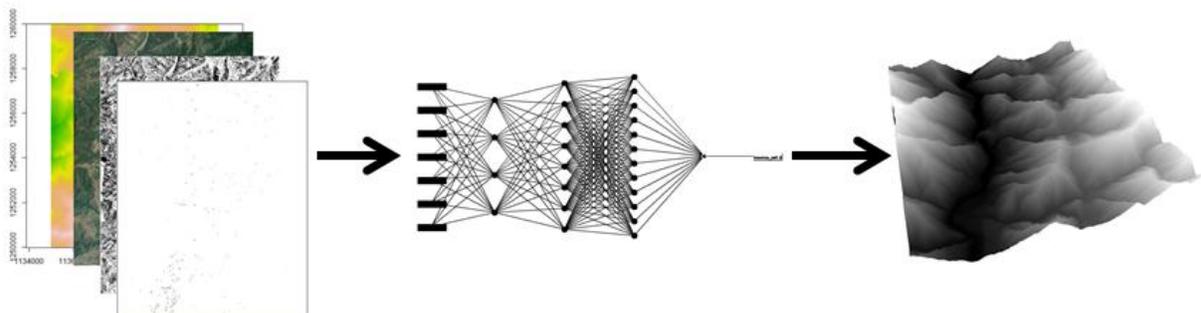


Imagen 5 Proceso general en la metodología, fuente (Autor)



6.2.1 Selección del patrón de búsqueda

Acá se establece claramente la conceptualización del problema a través del diseño de un razonamiento procedural que da solución a este, dentro de esta actividad se modela el patrón de búsqueda inicial (fundamental para el proceso de correspondencia).

En este caso se tiene como objetivo, ejecutar el proceso de correlación entre imágenes para que fundamentalmente encuentre los puntos correspondientes entre pares estereoscópicos en base al valor de disparidad dentro del rango de $[0, d_{max}]$, en donde la disparidad máxima se obtiene donde no exista una pérdida de similitud entre los valores radiométricos de los puntos.

Ya que se cuenta con un par de imágenes, una izquierda (*iz*) y una derecha (*de*), se procede a hacer el escaneo pixel por pixel con la función o modelo de correlación seleccionado $f_{iz}(x, y) \rightarrow f_{de}(x + d_{max}, y)$ teniendo como referencia la imagen *iz* dentro del rango $[f_{de}(x, y), \dots, f_{de}(x + d_{max}, y)]$ en donde se evalúan los valores obtenidos y se seleccionan los candidatos similares. Como resultado se obtiene un modelo digital de elevación MDE el cual suministra el valor de cada uno de los puntos sobre la superficie observable en las imágenes.

Seguido se procede a seleccionar las variables y datos a utilizar en el proceso de entrenamiento de la RNA con el fin de obtener el MDT. Una de las variables es el MDE en donde se definen los puntos que necesitan o no la reducción en su altura dependiendo de las otras variables a evaluar; acá es donde interviene el mapa de clasificación del suelo obtenido previamente. También se tiene un muestreo de varios puntos homólogos sobre la zona en donde se tiene la altura a nivel de MDT y MDE (puntos capturados con fotogrametría digital). Y por último se cuenta con las capas que identifican la tonalidad o firma espectral de cada una de las coberturas en la zona de estudio. Con esta información se procede a buscar la función adecuada para la determinación del MDT a través de la asignación del peso adecuado para cada una de estas y la selección del número de capas en la red que permitan obtener el mejor resultado y una eficiencia



optima en cuanto a la ejecución de los procesos en el equipo de cómputo utilizado; este proceso se puede ver de manera general en la imagen 5.

6.2.2 Determinación del mecanismo de inferencia

A continuación se seleccionan las funciones y procedimientos en que se basan tanto la técnica de correlación y el modelo de red neuronal artificial, cuyo propósito es obtener los datos de disparidad de una zona específica y a partir de este el valor de la altura de cada punto. También se traducirán estas funciones a estructuras lógicas, a su vez plasmadas en las líneas de código que ejecutarán los procedimientos previamente definidos en los requerimientos.

6.2.2.1 Función de correlación y modelo de red neuronal

Inicialmente en esta actividad se determina la función solución al problema planteado a través del modelo de correlación por *mínimos cuadrados* mediante la siguiente expresión:

$$CC(x, y, d) = \sum_{i=-n}^n \sum_{j=-n}^n \frac{f_{iz}(x+i, y+j) - M(x+i, y+j)}{\sqrt{S_{iz}(x+i, y+j)^2}} \cdot \frac{f_{de}(x+i, y+j+d) - M(x+i, y+j+d)}{\sqrt{S_{de}(x+i, y+j)^2}} \quad (Ec. 22)$$

En donde $M(x, y)$ y $S(x, y)$ son la media y la desviación estándar respectivamente.



Seguido a esto se determina el modelo de RNA, el cual se define de manera general mediante la siguiente expresión:

$$d(f_{iz}, f_{de}) = \sum_{i=1}^n w_i^2 n_i^1 + b^2 \quad (\text{Ec. 23})$$

En donde w_i^2 representa los pesos, condicionados por los parámetros con los que se haya estructurado el proceso de aprendizaje y b^2 la línea límite o de corte.

6.2.3 Herramienta

En esta sección se selecciona el software con el que se desarrolla el proceso y por supuesto se detalla la ejecución del mismo en la generación de pruebas y obtención de resultados.

6.2.3.1 Identificación del software

El software que se selecciona inicialmente para la generación del MDE es *Agisoft PhotoScan Professional Edition Version 1.2.0* el cual es de uso privativo; este software es una solución avanzada en el modelamiento del terreno en 3D a partir de imágenes. Es basado en la última tecnología de reconstrucción en 3D llamada multi-vista o en inglés *Multi-View* y permite hacer la correlación entre los modelos estereoscópicos y la generación de la ortofoto de la zona a trabajar; una de las ventajas es que en el caso



que no se cuente con un sistema de referencia, el programa define uno arbitrario y ubica las fotos según puntos homólogos encontrados en cada una de ellas.

Seguido se hace uso del software WEKA versión 3.8.0 para hacer el modelo de RNA; este programa es una colección de algoritmos de aprendizaje para actividades en la minería de datos. Estos algoritmos se pueden aplicar directamente sobre el grupo de datos o se pueden invocar desde un código fuente de Java. Este programa es de uso libre y permite el procesamiento de gran cantidad de información desde que se cuente con los recursos tecnológicos adecuados.

6.2.3.2 Procedimiento

Inicialmente se define el área a trabajar, básicamente se buscó una zona donde su topografía tuviera cambios relevantes y permitiera una mejor visualización de los resultados obtenidos; esta área es la definida por las planchas 115IIIB1 y 115IIIB3 correspondientes a 7.500 Has en el departamento de Antioquia. A partir de los pares estereoscópicos de la zona, se procede a generar el MDE y la ortofoto de la zona a trabajar, estas imágenes fueron proveídas por el INSTITUTO GEOGRÁFICO AGUSTÍN CODAZZI - IGAC y cuentan con las políticas de manejo anexas en este documento (anexo 1).

Las imágenes se cargan en el programa *Agisoft PhotoScan Professional Edition* y se procede a realizar la alineación de estas para el proceso de generación del MDE, véase imagen 6.

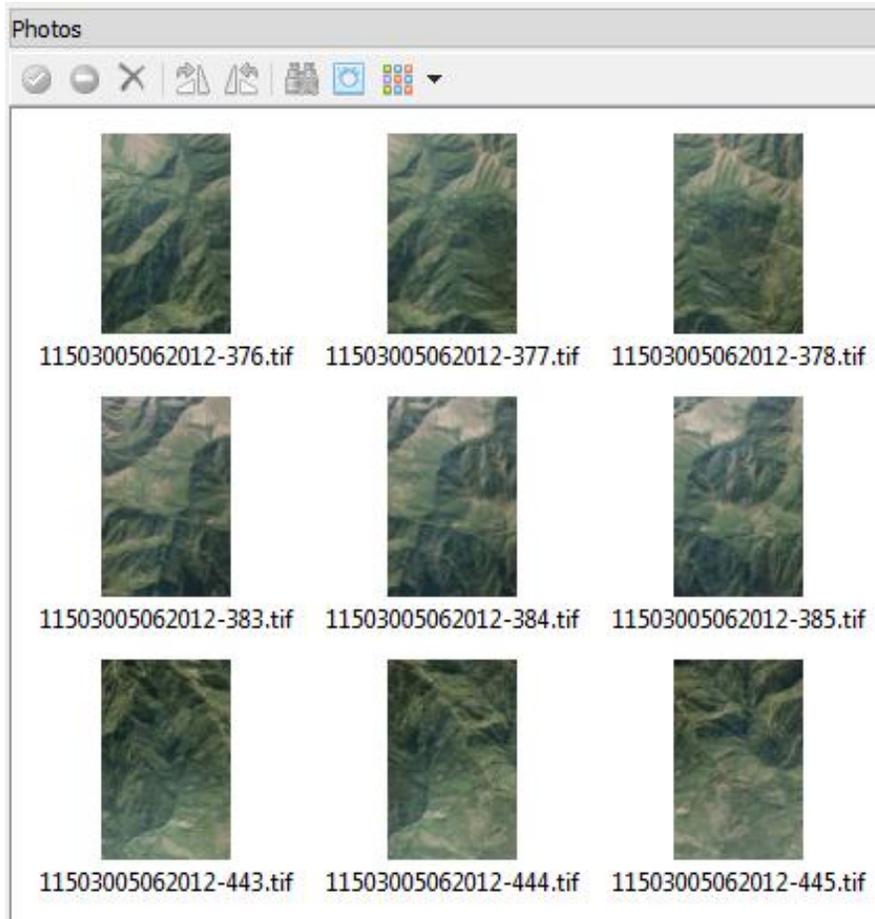


Imagen 6 Imágenes en la ventana de contenido del software Agisoft photoscan, fuente (Autor)

En general este procedimiento inicia creando una cantidad de puntos dispersos a partir de una primera correlación entre los pares estereoscópicos identificando los puntos homólogos en cada una de las imágenes como se puede ver en la imagen 7; con base en esto se genera una nube de puntos con los valores de altura en metros.

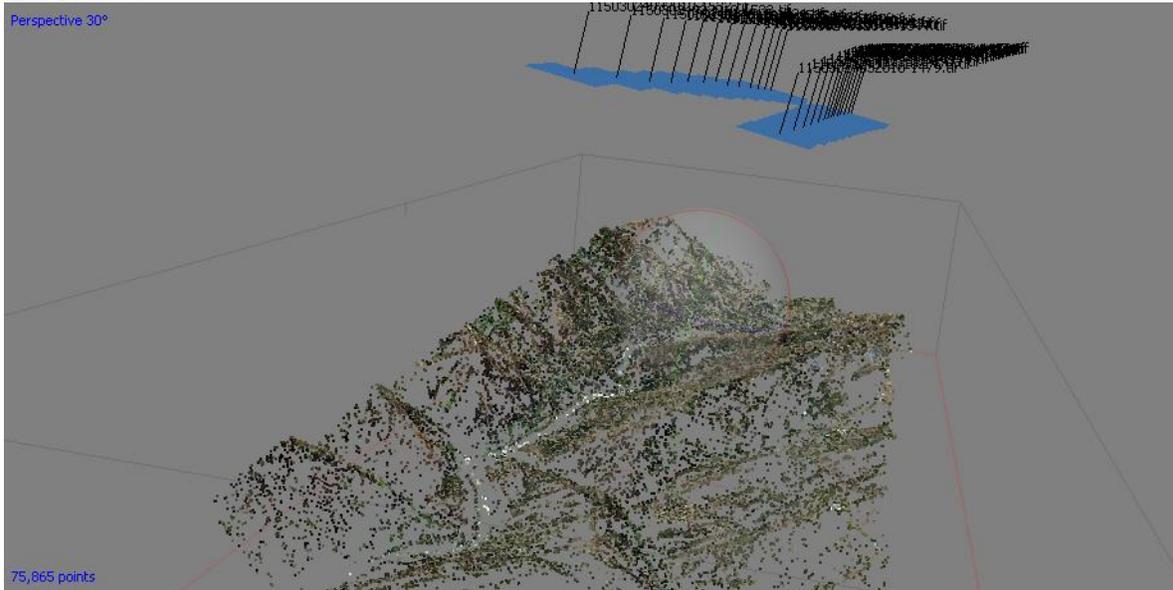


Imagen 7 Puntos homólogos detectados por el software para el proceso de correlación, fuente (Autor)

El paso siguiente es la generación del MDE de la zona de trabajo en donde se identifica la altura sobre la superficie de cada uno de los elementos sobre el terreno como vegetación, construcciones e infraestructura vial, véase imagen 8.

```
class      : RasterLayer
dimensions : 1002, 752, 753504 (nrow, ncol, ncell)
resolution : 10, 10 (x, y)
extent     : 1134987, 1142507, 1249981, 1260001 (xmin, xmax, ymin, ymax)
coord. ref. : +proj=tmerc +lat_0=4.596200416666666 +lon_0=-77.07750791666666 +k=1 +x_0=1000000
+y_0=1000000 +ellps=GRS80 +units=m +no_defs
data source : C:\Users\XXXXX\Desktop\infrar\dem_115_x10.img
names      : dem_115_x10
values     : 285, 1997 (min, max)
```

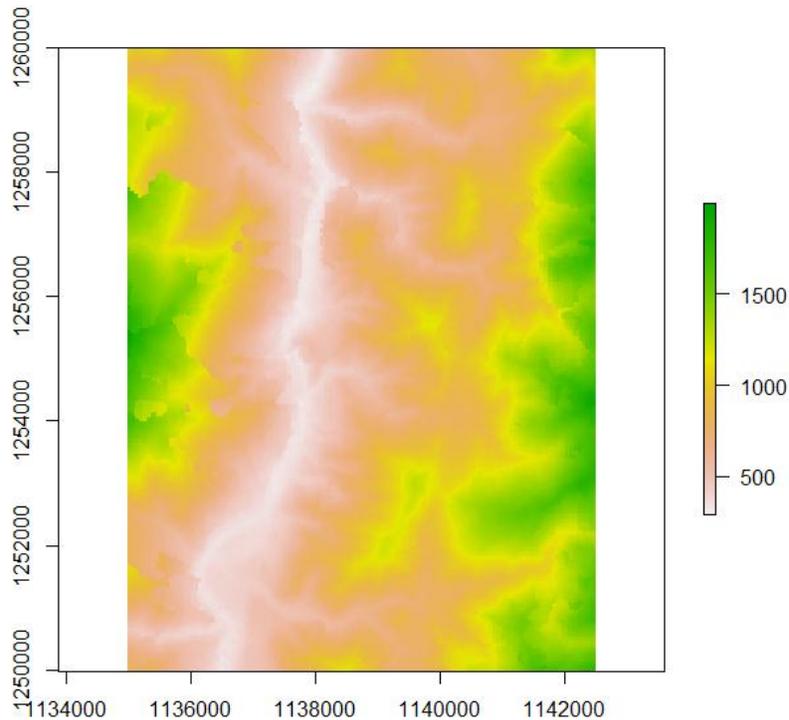


Imagen 8 Modelo Digital de Elevación (MDE), fuente (Autor)

Como último paso en este software se procede a generar la ortofoto del área de estudio, véase Imagen 9, en donde se aplica el MDE obtenido previamente para aplicar la deformación por la altura y se define el tamaño del pixel de manera que sea homogéneo entre las imágenes sometidas en el proceso de análisis posterior (10 m), a continuación la descripción.

```
class      : RasterLayer
band       : 1 (of 4 bands)
dimensions : 1001, 750, 750750 (nrow, ncol, ncell)
resolution : 10, 10 (x, y)
extent     : 1135000, 1142500, 1249990, 1260000 (xmin, xmax, ymin, ymax)
coord. ref. : +proj=tmerc +lat_0=4.596200416666666 +lon_0=-77.07750791666666 +k=1 +x_0=1000000
+y_0=1000000 +ellps=GRS80 +units=m +no_defs
data source : C:\Users\XXXX\Desktop\infrar\115IIIB_ortox10.tif
```



[[2]]

```
class      : RasterLayer
band       : 2 (of 4 bands)
dimensions : 1001, 750, 750750 (nrow, ncol, ncell)
resolution : 10, 10 (x, y)
extent     : 1135000, 1142500, 1249990, 1260000 (xmin, xmax, ymin, ymax)
coord. ref. : +proj=tmerc +lat_0=4.596200416666666 +lon_0=-77.07750791666666 +k=1 +x_0=1000000
+y_0=1000000 +ellps=GRS80 +units=m +no_defs
data source : C:\Users\XXXX\Desktop\infrar\115IIIB_ortox10.tif
```

[[3]]

```
class      : RasterLayer
band       : 3 (of 4 bands)
dimensions : 1001, 750, 750750 (nrow, ncol, ncell)
resolution : 10, 10 (x, y)
extent     : 1135000, 1142500, 1249990, 1260000 (xmin, xmax, ymin, ymax)
coord. ref. : +proj=tmerc +lat_0=4.596200416666666 +lon_0=-77.07750791666666 +k=1 +x_0=1000000
+y_0=1000000 +ellps=GRS80 +units=m +no_defs
data source : C:\Users\XXXX\Desktop\infrar\115IIIB_ortox10.tif
```

[[4]]

```
class      : RasterLayer
band       : 4 (of 4 bands)
dimensions : 1001, 750, 750750 (nrow, ncol, ncell)
resolution : 10, 10 (x, y)
extent     : 1135000, 1142500, 1249990, 1260000 (xmin, xmax, ymin, ymax)
coord. ref. : +proj=tmerc +lat_0=4.596200416666666 +lon_0=-77.07750791666666 +k=1 +x_0=1000000
+y_0=1000000 +ellps=GRS80 +units=m +no_defs
data source : C:\Users\XXXX\Desktop\infrar\115IIIB_ortox10.tif
```

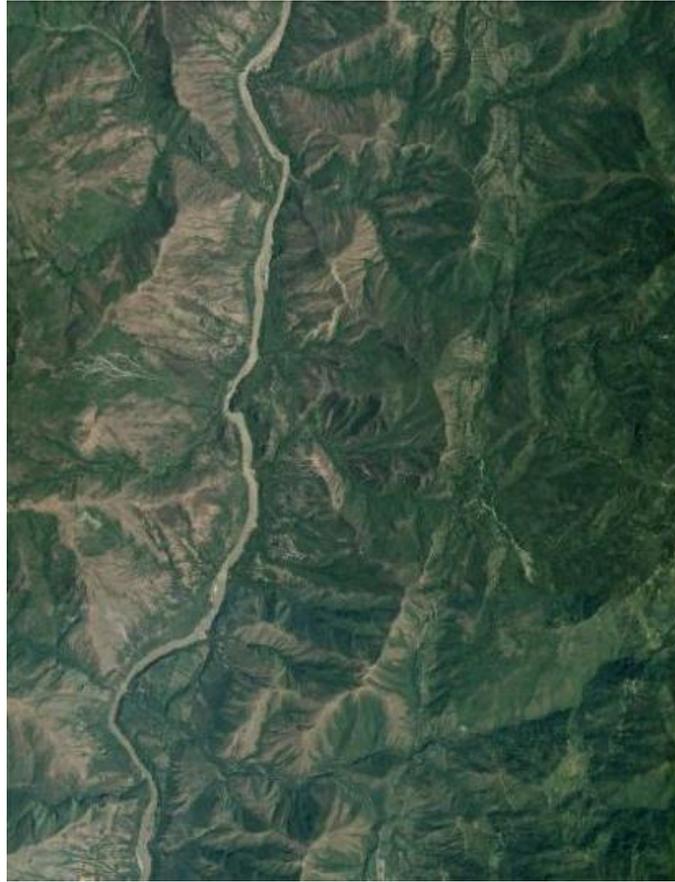


Imagen 9 Ortofoto del área de estudio con combinación RGB en verdadero color, fuente (Autor)

Seguido y con ayuda de la ortofoto generada, se procede a crear una clasificación no supervisada en donde se detectan los diferentes elementos sobre la superficie de la tierra según su composición RGB en verdadero color; se van a analizar los resultados obtenidos con cinco clasificaciones y posteriormente con 10 como se observa en la imagen 10, a continuación la descripción:

```
class      : RasterLayer
dimensions : 1001, 750, 750750  (nrow, ncol, ncell)
resolution : 10, 10  (x, y)
extent     : 1135000, 1142500, 1249990, 1260000  (xmin, xmax, ymin, ymax)
coord. ref. : +proj=tmerc +lat_0=4.596200416666666 +lon_0=-77.07750791666666 +k=1 +x_0=1000000
+y_0=1000000 +ellps=GRS80 +units=m +no_defs
```



data source : C:\Users\XXXX\Desktop\infrar\115IIIB_15cls.tif

names : X115IIIB_15cls

values : 0, 10 (min, max)

attributes :

	ID	OID	Value	Count	Class_Names
from:	0	0	0	0	Unclassified
to :	10	10	10	8936356	Class 10

class : RasterLayer

dimensions : 1001, 750, 750750 (nrow, ncol, ncell)

resolution : 10, 10 (x, y)

extent : 1135000, 1142500, 1249990, 1260000 (xmin, xmax, ymin, ymax)

coord. ref. : +proj=tmerc +lat_0=4.596200416666666 +lon_0=-77.07750791666666 +k=1 +x_0=1000000
+y_0=1000000 +ellps=GRS80 +units=m +no_defs

data source : C:\Users\XXXX\Desktop\infrar\115IIIB_16cls.tif

names : X115IIIB_16cls

values : 0, 5 (min, max)

attributes :

	ID	OID	Value	Count	Class_Names
from:	0	0	0	0	Unclassified
to :	5	5	5	19110763	Class 5

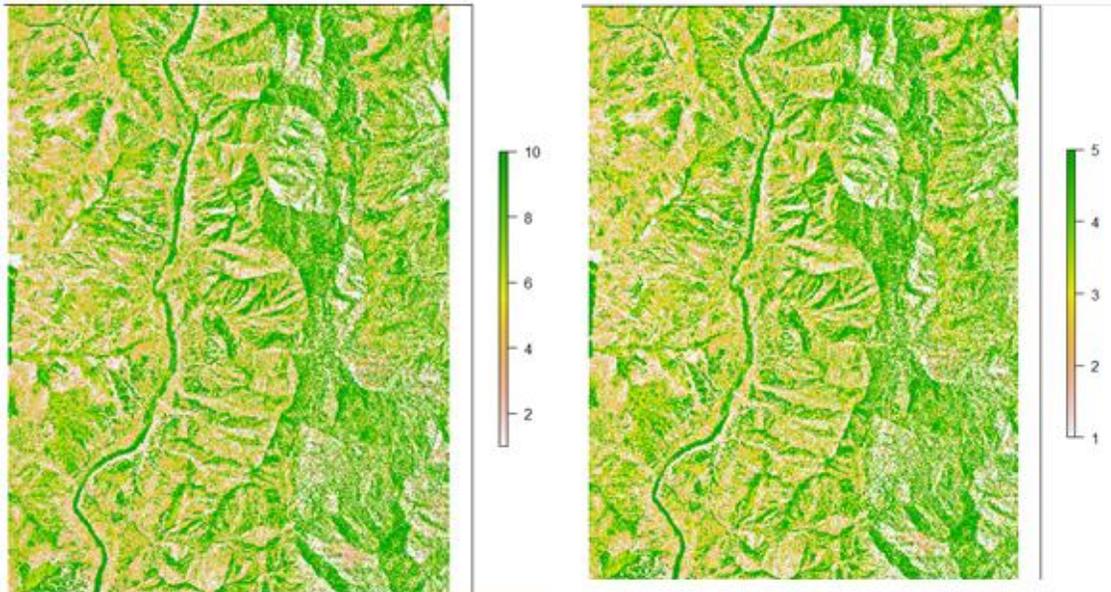


Imagen 10 Imágenes con 10 y 5 clases de izquierda a derecha respectivamente, fuente (Autor)

Finalmente en la etapa de adquisición de los insumos para el procedimiento y con ayuda de los modelos estereoscópicos, se procede a capturar unos puntos, véase Imagen 11, en zonas descubiertas como en pastos y áreas de claros en los bosques con el fin de indicar el comportamiento del terreno y así ajustar con precisión la función que defina este.

```
class      : RasterLayer
dimensions : 993, 735, 729855  (nrow, ncol, ncell)
resolution : 10, 10  (x, y)
extent     : 1135125, 1142475, 1250044, 1259974  (xmin, xmax, ymin, ymax)
coord. ref. : +proj=tmerc +lat_0=4.596200416666666 +lon_0=-77.07750791666666 +k=1 +x_0=1000000
+y_0=1000000 +ellps=GRS80 +units=m +no_defs
data source : C:\Users\XXXX\Desktop\infrar\points_115x10.img
names      : points_115x10
values     : 322, 1834  (min, max)
```

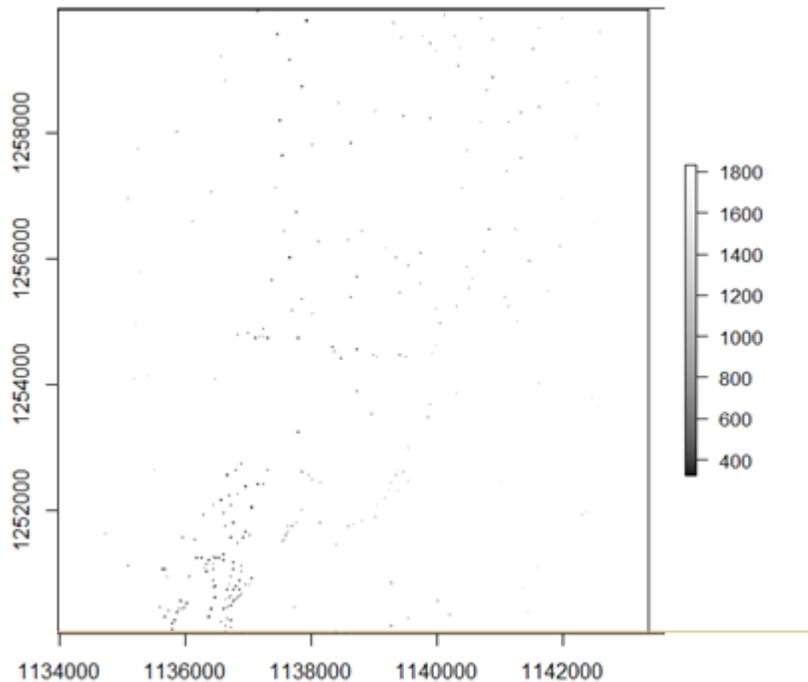


Imagen 11 Puntos capturados con los modelos estereoscópicos en zonas descubiertas, fuente (Autor)

En la Imagen 12 se ven las imágenes (capas) que son el insumo para el entrenamiento de la red neuronal y posterior ejecución del modelo seleccionado. También en la imagen 13 se observa la distribución de los datos en cada capa con ayuda de su respectivo histograma. Cabe recordar que el análisis y generación de los resultados en la RNA se hace inicialmente con 5 clases y posteriormente con 10. En la siguiente descripción se observa las capas que agrupadas en un solo archivo para su análisis; son 8 ya que el archivo de la ortofoto está compuesto por 4 bandas, rojo verde, azul e infrarrojo.



[[1]]

```
class      : RasterLayer
band       : 1 (of 8 bands)
dimensions : 1003, 753, 755259 (nrow, ncol, ncell)
resolution : 9.99363, 9.99363 (x, y)
extent     : 1134987, 1142513, 1249981, 1260005 (xmin, xmax, ymin, ymax)
coord. ref. : +proj=tmerc +lat_0=4.596200416666666 +lon_0=-77.07750791666666 +k=1 +x_0=1000000
+y_0=1000000 +ellps=GRS80 +units=m +no_defs
data source : C:\Users\XXXX\Desktop\infrar\datos\insumos_set1.tif
names      : insumos_set1.1
values     : 322, 1834 (min, max)
```

[[2]]

```
class      : RasterLayer
band       : 2 (of 8 bands)
dimensions : 1003, 753, 755259 (nrow, ncol, ncell)
resolution : 9.99363, 9.99363 (x, y)
extent     : 1134987, 1142513, 1249981, 1260005 (xmin, xmax, ymin, ymax)
coord. ref. : +proj=tmerc +lat_0=4.596200416666666 +lon_0=-77.07750791666666 +k=1 +x_0=1000000
+y_0=1000000 +ellps=GRS80 +units=m +no_defs
data source : C:\Users\XXXX\Desktop\infrar\datos\insumos_set1.tif
names      : insumos_set1.2
values     : -3.402823e+38, 1985 (min, max)
```

[[3]]

```
class      : RasterLayer
band       : 3 (of 8 bands)
dimensions : 1003, 753, 755259 (nrow, ncol, ncell)
resolution : 9.99363, 9.99363 (x, y)
extent     : 1134987, 1142513, 1249981, 1260005 (xmin, xmax, ymin, ymax)
coord. ref. : +proj=tmerc +lat_0=4.596200416666666 +lon_0=-77.07750791666666 +k=1 +x_0=1000000
+y_0=1000000 +ellps=GRS80 +units=m +no_defs
```



```
data source : C:\Users\XXXX\Desktop\infrar\datos\insumos_set1.tif
```

```
names       : insumos_set1.3
```

```
values      : 0, 5 (min, max)
```

```
[[4]]
```

```
class       : RasterLayer
```

```
band        : 4 (of 8 bands)
```

```
dimensions  : 1003, 753, 755259 (nrow, ncol, ncell)
```

```
resolution  : 9.99363, 9.99363 (x, y)
```

```
extent      : 1134987, 1142513, 1249981, 1260005 (xmin, xmax, ymin, ymax)
```

```
coord. ref. : +proj=tmerc +lat_0=4.596200416666666 +lon_0=-77.07750791666666 +k=1 +x_0=1000000  
+y_0=1000000 +ellps=GRS80 +units=m +no_defs
```

```
data source : C:\Users\XXXX\Desktop\infrar\datos\insumos_set1.tif
```

```
names       : insumos_set1.4
```

```
values      : 285, 1997 (min, max)
```

```
[[5]]
```

```
class       : RasterLayer
```

```
band        : 5 (of 8 bands)
```

```
dimensions  : 1003, 753, 755259 (nrow, ncol, ncell)
```

```
resolution  : 9.99363, 9.99363 (x, y)
```

```
extent      : 1134987, 1142513, 1249981, 1260005 (xmin, xmax, ymin, ymax)
```

```
coord. ref. : +proj=tmerc +lat_0=4.596200416666666 +lon_0=-77.07750791666666 +k=1 +x_0=1000000  
+y_0=1000000 +ellps=GRS80 +units=m +no_defs
```

```
data source : C:\Users\XXXX\Desktop\infrar\datos\insumos_set1.tif
```

```
names       : insumos_set1.5
```

```
values      : 2, 256 (min, max)
```

```
[[6]]
```



```
class      : RasterLayer
band       : 6 (of 8 bands)
dimensions : 1003, 753, 755259 (nrow, ncol, ncell)
resolution : 9.99363, 9.99363 (x, y)
extent     : 1134987, 1142513, 1249981, 1260005 (xmin, xmax, ymin, ymax)
coord. ref. : +proj=tmerc +lat_0=4.596200416666666 +lon_0=-77.07750791666666 +k=1 +x_0=1000000
+y_0=1000000 +ellps=GRS80 +units=m +no_defs
data source : C:\Users\XXXX\Desktop\infrar\datos\insumos_set1.tif
names      : insumos_set1.6
values     : 5, 256 (min, max)
```

[[7]]

```
class      : RasterLayer
band       : 7 (of 8 bands)
dimensions : 1003, 753, 755259 (nrow, ncol, ncell)
resolution : 9.99363, 9.99363 (x, y)
extent     : 1134987, 1142513, 1249981, 1260005 (xmin, xmax, ymin, ymax)
coord. ref. : +proj=tmerc +lat_0=4.596200416666666 +lon_0=-77.07750791666666 +k=1 +x_0=1000000
+y_0=1000000 +ellps=GRS80 +units=m +no_defs
data source : C:\Users\XXXX\Desktop\infrar\datos\insumos_set1.tif
names      : insumos_set1.7
values     : 3, 256 (min, max)
```

[[8]]

```
class      : RasterLayer
band       : 8 (of 8 bands)
dimensions : 1003, 753, 755259 (nrow, ncol, ncell)
resolution : 9.99363, 9.99363 (x, y)
extent     : 1134987, 1142513, 1249981, 1260005 (xmin, xmax, ymin, ymax)
coord. ref. : +proj=tmerc +lat_0=4.596200416666666 +lon_0=-77.07750791666666 +k=1 +x_0=1000000
+y_0=1000000 +ellps=GRS80 +units=m +no_defs
data source : C:\Users\XXXX\Desktop\infrar\datos\insumos_set1.tif
```



names : insumos_set1.8
values : 1, 256 (min, max)

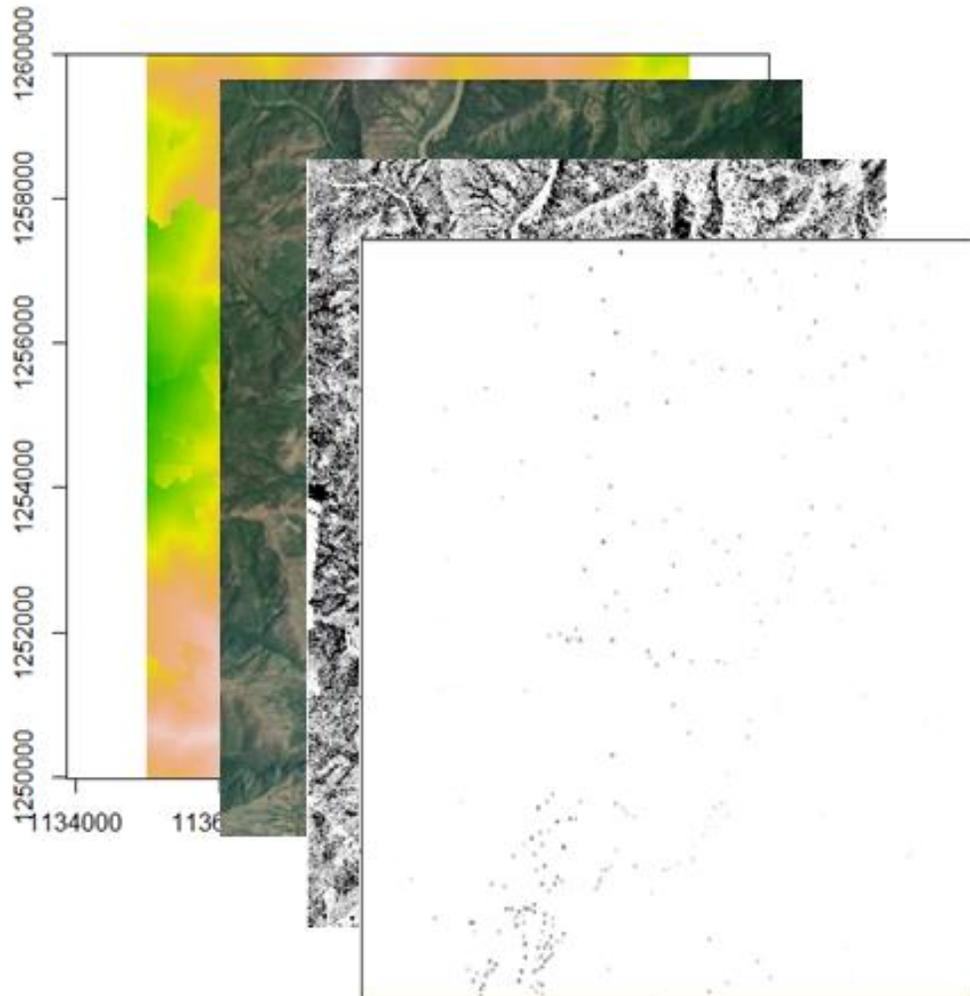


Imagen 12 Capas de insumo en el proceso, fuente (Autor)

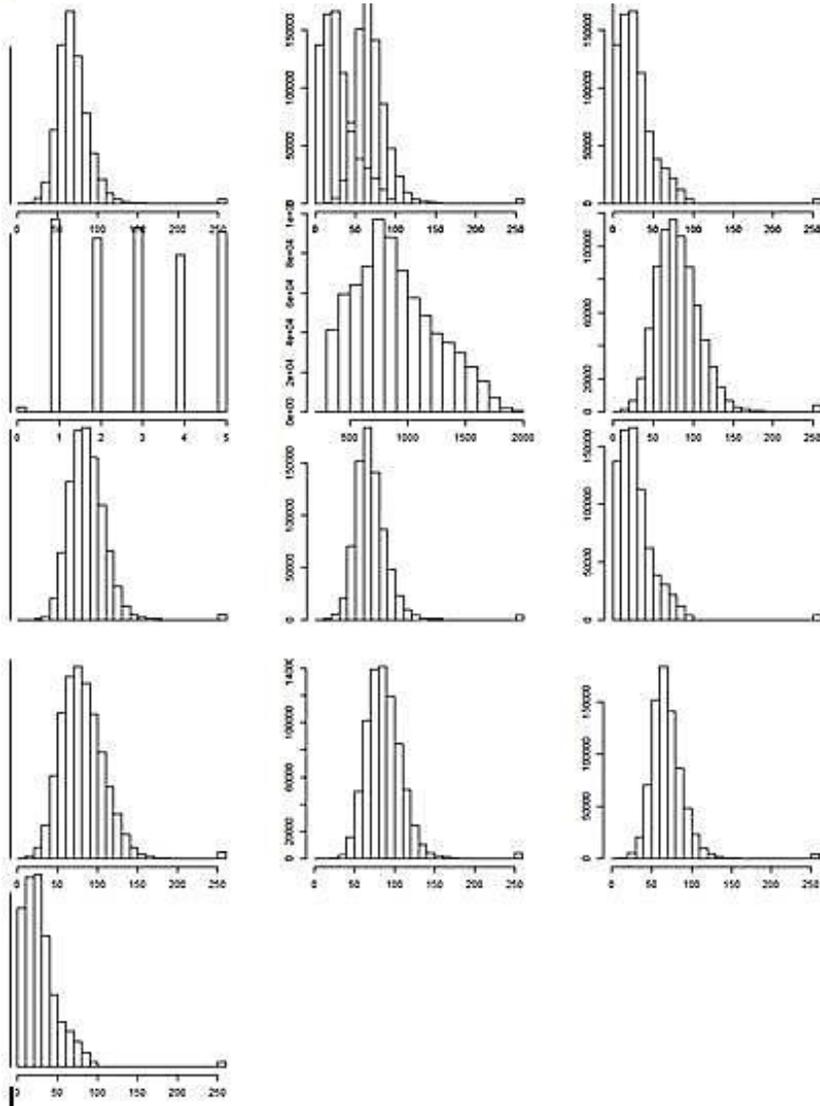


Imagen 13 Histogramas de las capas insumo del proceso, fuente (Autor)

En el software WEKA versión 3.8.0 se procede a cargar la información; debido a que este programa trabaja con el formato de archivos *.arff *Attribute-Relation File Format*, que es un formato de archivos tipo ASCII que enlista los valores de diferentes atributos con sus diferentes tipos de datos según sea el caso; en este proyecto los atributos son: los valores de altura de las imágenes del MDE y los puntos tomados en terreno, los valores



según la clasificación del elemento detectado en la ortofoto, y los valores o niveles digitales de las bandas RGBI del área, véase Imagen 14.

```
@relation R_data_frame

@attribute x numeric
@attribute y numeric
@attribute insumos_set1.1 numeric
@attribute insumos_set1.2 numeric
@attribute insumos_set1.3 numeric
@attribute insumos_set1.4 numeric
@attribute insumos_set1.5 numeric
@attribute insumos_set1.6 numeric
@attribute insumos_set1.7 numeric
@attribute insumos_set1.8 numeric

@data
1134992.496815,1260000.003185,?,1043,0,1072,256,256,256,256
1135002.490445,1260000.003185,?,1043,0,1072,256,256,256,256
1135012.484075,1260000.003185,?,1035,0,1072,256,256,256,256
1135022.477706,1260000.003185,?,1030,0,1054,256,256,256,256
1135032.471336,1260000.003185,?,1025,0,1054,256,256,256,256
1135042.464966,1260000.003185,?,1023,0,1054,256,256,256,256
1135052.458596,1260000.003185,?,1021,0,1027,256,256,256,256
1135062.452226,1260000.003185,?,1020,0,1027,256,256,256,256
1135072.445857,1260000.003185,?,1019,0,1027,256,256,256,256
1135082.439487,1260000.003185,?,1019,0,1021,256,256,256,256
```

Imagen 14 Estructura básica de un archivo *.arff, fuente (Autor)

Posteriormente los datos se cargan y se procede a hacer los experimentos; acá se define la estructura del modelo de RNA con las capas de entrada, la definición del número de capas ocultas y el número de neuronas en cada una de ellas con el fin de obtener el mejor resultado, traducido en la capa de salida que define el MDT sin olvidar el número de conexiones o pesos necesarios para su obtención; cada neurona o nodo realiza la suma de estos pesos y define los resultados según el umbral establecido en base a la función sigmoideal del algoritmo. El proceso de aprendizaje se realiza minimizando en el error iterativamente usando el método de *descenso de gradiente* en donde el gradiente es determinado usando el algoritmo *Backpropagation*. El cambio de peso en cada iteración es calculado con base a la multiplicación del gradiente por una constante



llamada *taza de aprendizaje (learning rate)* y sumando el cambio del peso anterior multiplicado por otro parámetro llamado *momentum*.

Estos valores o parámetros son los que se modifican con el fin de analizar los resultados obtenidos. A continuación se puede observar los parámetros definidos en el proceso de experimentación:

- Clasificador *Perceptron multi-capas*, en donde los experimentos se ejecutan con 1, 2 y 3 capas ocultas modificando el número de neuronas en cada una, iniciando con los valores por defecto.
- Se modifica el número de iteraciones en el proceso de aprendizaje con incrementos de 100 a partir del valor por defecto hasta 1000.
- Se modifica el valor de la tasa de aprendizaje y el momentum incrementando 0,1 a partir de los valores proporcionados por defecto sin exceder el valor igual a 1.

A continuación en las imágenes 15, 16 y 17 se pueden observar los modelos de RNA utilizados en los experimentos y los cuales cumplen con los parámetros previamente mencionados.

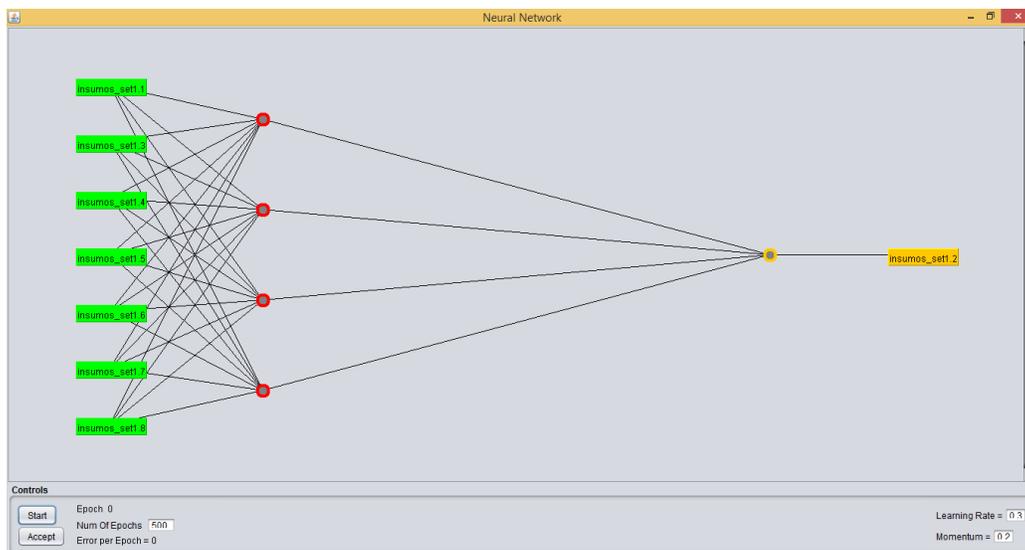


Imagen 15 Modelo de RNA con una capa y 4 neuronas, fuente (Autor)

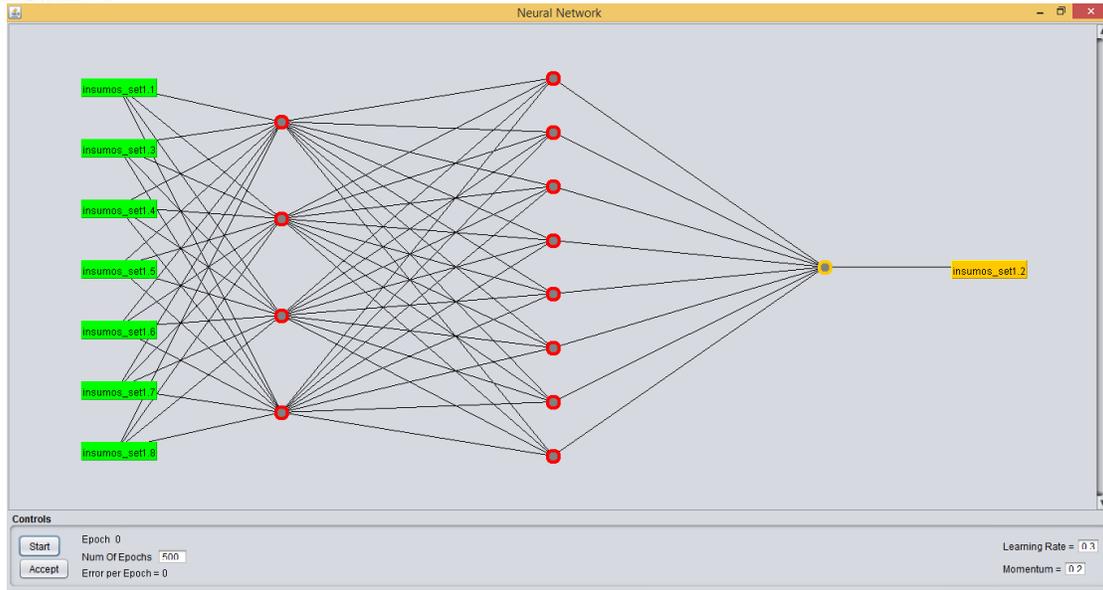


Imagen 16 Modelo de RNA con dos capas y 12 neuronas, fuente (Autor)

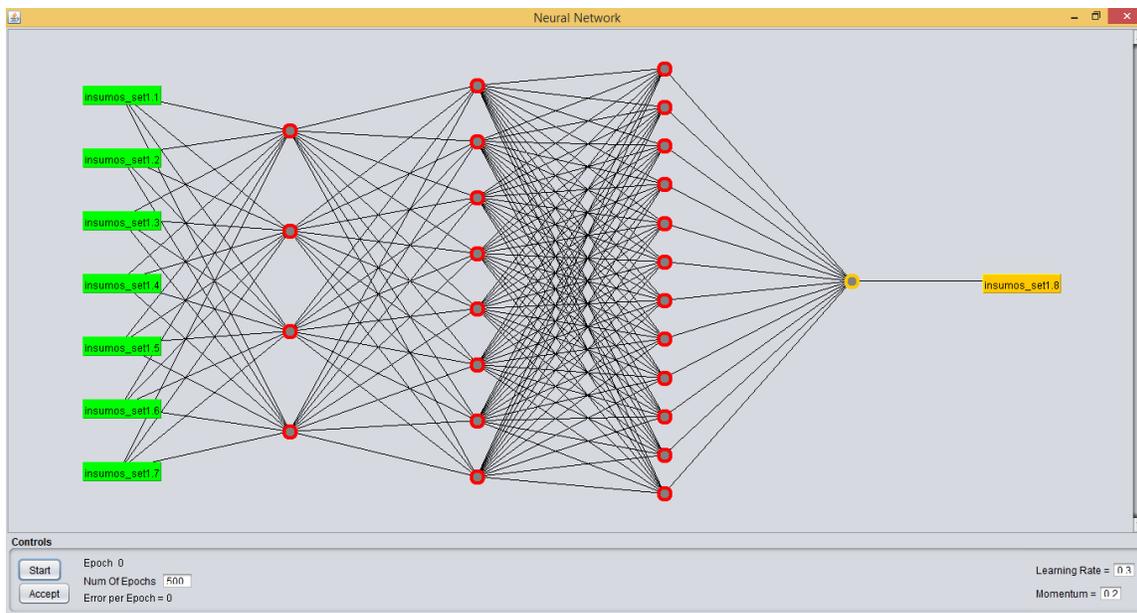


Imagen 17 Modelo de RNA con tres capas y 24 neuronas, fuente (Autor)



6.3 Etapa de análisis de resultados

Inicialmente se procesa el grupo de datos con las 5 clasificaciones y posteriormente con 10, de la misma forma se cambian los valores especificados en los parámetros de la red neuronal; estos experimentos se realizan con un grupo de datos denominado *datos de entrenamiento*, que corresponden al 20% del total de los datos trabajados. A continuación se observan las tablas con los resultados obtenidos y los parámetros utilizados.

El primer parámetro que se modifica es el número de iteraciones de 500 a 1000 incrementando de 100 en 100 con los demás valores por defecto y en donde no se observa ningún cambio en el resultado del coeficiente de correlación, véase tabla 1,2 y 3.

PARÁMETROS		COEF DE CORRELACIÓN
Iteraciones	500	0,7784
taza de aprendizaje	0,3	
Momentum	0,2	
Iteraciones	600	0,7784
taza de aprendizaje	0,3	
Momentum	0,2	
Iteraciones	700	0,7784
taza de aprendizaje	0,3	
Momentum	0,2	
Iteraciones	800	0,7784
taza de aprendizaje	0,3	
Momentum	0,2	
Iteraciones	900	0,7784
taza de aprendizaje	0,3	
Momentum	0,2	
Iteraciones	1000	0,7784
taza de aprendizaje	0,3	
Momentum	0,2	

Tabla 1 Experimentos con cambio de numero de iteraciones con una capa de cuatro neuronas, fuente (Autor)



PARÁMETROS		COEF DE CORRELACIÓN
Iteraciones	500	0,8418
taza de aprendizaje	0,3	
Momentum	0,2	
Iteraciones	600	0,8419
taza de aprendizaje	0,3	
Momentum	0,2	
Iteraciones	700	0,8419
taza de aprendizaje	0,3	
Momentum	0,2	
Iteraciones	800	0,8419
taza de aprendizaje	0,3	
Momentum	0,2	
Iteraciones	900	0,8419
taza de aprendizaje	0,3	
Momentum	0,2	
Iteraciones	1000	0,8419
taza de aprendizaje	0,3	
Momentum	0,2	

Tabla 2 Experimentos con cambio de numero de iteraciones con dos capas y un total de 12 neuronas, fuente (Autor)

PARÁMETROS		COEF DE CORRELACION
Iteraciones	500	0,8445
taza de aprendizaje	0,3	
Momentum	0,2	
Iteraciones	600	0,8445
taza de aprendizaje	0,3	
Momentum	0,2	
Iteraciones	700	0,8445
taza de aprendizaje	0,3	
Momentum	0,2	
Iteraciones	800	0,8445
taza de aprendizaje	0,3	
Momentum	0,2	
Iteraciones	900	0,8445
taza de aprendizaje	0,3	
Momentum	0,2	



Iteraciones	1000	0,8445
taza de aprendizaje	0,3	
Momentum	0,2	

Tabla 3 Experimentos con cambio de número de iteraciones con tres capas y un total de 24 neuronas, fuente (Autor)

Paso seguido se inicia con el cambio en el valor de los demás parámetros como lo es el de tasa de aprendizaje y momentum, en este caso también se toma el dato del error acumulado y el valor del umbral al cual se ajusta el peso en cada unión entre neuronas o nodos; en la tabla 4, 5 y 6 del anexo 2, se observan los datos obtenidos con las capas experimentadas. Por cuestiones de visualización el número de decimales se ha reducido, pero en las tablas adjuntas a este documento se encuentra la información original.

Según estos resultados, en el primer modelo de RNA con una capa y 4 nodos o neuronas, el mejor resultado en el coeficiente de correlación es 0,8203 el cual es obtenido con valores en la tasa de aprendizaje y momentum de 0,7 y 0,2 respectivamente, sin embargo el valor del error acumulado en las iteraciones es igual a 0,01019; en este caso se evalúan los resultados que cumplan la condición de tener un valor alto de correlación y bajo en el error acumulado. En este sentido se seleccionan los valores de tasa de aprendizaje 0,1 y momentum 0,4 que arrojan resultados de 0,802 en coeficiente de correlación y un error acumulado de 0,005199 en las iteraciones.

En este modelo también se puede observar como a medida que aumenta el valor de la tasa de aprendizaje también el error acumulado, de la misma forma que ocurre a incrementar el valor del momentum tanto que los últimos experimentos con los valores más altos no se realizaron porque surge una excepción en el programa que indica usar valores más bajos para poder ejecutar el proceso; también se observa como los valores de los umbrales aumentan, esto indica que en el modelo se deben ajustar excesivamente los pesos para obtener el resultado esperado.



Igual que en el análisis anterior, en el modelo de RNA con dos capas y 12 neuronas, la mejor combinación entre los valores de tasa de aprendizaje y momentum es de 0,1 y 0,3 respectivamente en donde se obtiene valores de coeficiente de correlación de 0,8447 y un error acumulado de 0,0045073.

Finalmente y según los parámetros iniciales en el proceso de experimentación, se observa que la mejor selección y combinación de parámetros para obtener los mejores resultados es un modelo de RNA con 3 capas, en cada una con 4, 8 y 12 neuronas respectivamente, con valores en la tasa de aprendizaje de 0,1 y 0,2 para el momentum; con estos valores se obtiene resultados en el coeficiente de correlación de 0,9823 y un error acumulado de 0,00444; en el anexo 3, se observa detalladamente el resumen de los valores obtenidos en este modelo.

En este resumen se observa un muy buen valor de correlación en el proceso global, ya que se aproxima casi a 1, al mismo tiempo se observa la correlación de las variables de entrada y su importancia en el proceso; se puede apreciar que el ajuste de los pesos de signo negativo se presentan en las variables correspondientes a las bandas con los niveles digitales de la zona, esto quiere decir que estas no aportan mucho al momento de definir la altura sobre el terreno, y era de esperarse ya que la correlación entre los niveles digitales da la altura de los elementos visibles en la imagen o lo que se llama el MDE. Hay que tener en cuenta la información relevante en el cálculo de la altura sobre el terreno para de esta forma agregar la apropiada según los objetivos del análisis que se proponga; en este caso es recomendable para futuras investigaciones agregar información relacionada con la hidrografía, geología, pluviometría, entre otras con el fin de aprobar o descartar su importancia en este proceso.

Por otro lado, al evaluar el conjunto de datos con 10 clasificaciones, se obtienen valores similares a los anteriores, por tal razón se puede afirmar que no tiene trascendencia densificar la clasificación a más de 5.



7. CONCLUSIONES Y RECOMENDACIONES

- En el proceso de implementación y comprobación de la metodología evaluada para la obtención de MDT se identificaron y detallaron los documentos preliminares al diseño.
- Como se puede observar en los datos analizados, evidentemente la agregación de una RNA en el proceso, correlaciona las variables que intervienen en un alto nivel y reduce considerablemente el porcentaje de error en el modelo final.
- Con los programas de software seleccionados y los parámetros en a RNA definidos en la evaluación de la metodología, se logró definir el procedimiento general para el desarrollo del proyecto y comprobación de los resultados.
- Se concluye que entre más capas neuronales se le agregue al modelo de RNA se van a obtener mejores valores de correlación; adicionalmente si se ejecuta esta correlación disminuyendo el tamaño del pixel, se contará con mayor detalle en los resultados.
- Debe tenerse en cuenta el incremento del costo computacional a medida que se van ajustando los valores de los parámetros y características de las variables que intervienen en el proceso con el fin de aumentar la precisión de los resultados, esto puede requerir unas mejores características en los componentes del equipo y ocasionar problemas en los que no cuenten con estas.
- En la evaluación de la metodología se pudo crear, implementar y probar un modelo de RNA que permite obtener resultados validos a través del software WEKA 3.8



- En futuras investigaciones vale la pena incluir otro tipo de información relacionada en el cálculo del MDT, ya que esto enriquecería el proceso inicial de aprendizaje con los datos de entrenamiento; dentro de estos datos pueden estar los relacionados con información pluviométrica, geológica, hidrológica, entre otras. Su idoneidad se decidirá según los resultados obtenidos.
- Se debe tener en cuenta en el momento del levantamiento y preparación de la información de insumo, la calidad de los resultados que se pretendan obtener o el tipo de proyecto para el cual se van a utilizar, ya que de esto depende que el resultado sirva eficientemente como herramienta en la toma de decisiones.



8. BIBLIOGRAFÍA

- Adjouadi, M., & Candocia, F. (1994). A Stereo Matching Paradigm Based on the Walsh Transformation. *IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE*, 7.
- Binaghi, E., Gallo, I., Marino, G., & Raspanti, M. (2004). Neural adaptive stereo matching. *Pattern Recognition Letters*, 16.
- Bishop, C. M. (1995). *Neural Networks for Pattern Recognition*. Birmingham, UK: CLARENDON PRESS • OXFORD.
- Buitrago Aguilar, P. (1997). Fotogrametria digital, su estado y su futuro. *revista CIAF*, 23.
- Cai, X., Zhou, D., Li, G., & Zhuang, Z. (2005). A Stereo Matching Algorithm Based on Color Segments. 6.
- CHONG, M. M., GAY, R. K., NGEETAN, H., & LIU, J. (2000). GEOMETRIC KNOWLEDGE-BASED SYSTEMS FRAMEWORK FOR STEREO IMAGE MATCHING. In N. T. University. Singapore: Academic Press.
- El Garouani, A., Alobeid, A., & El Garouani, S. (2014). Digital surface model based on aerial image stereo pairs for 3D building. *International Journal of Sustainable Built Environment*, 8.
- El-Sheimy, N., Valeo, C., & Habib, A. (2005). *Digital Terrain Modeling: Acquisition, Manipulation And Applications*. Artech House.
- Gallo, I., Binaghi, E., & Raspanti, M. (2008). Neural disparity computation for dense two-frame stereo correspondence. *Pattern Recognition Letters*, 15.



- Geman, D., & Gidas, B. (1991). *Spatial Statistics and Digital Image Analysis*. Washington, D.C.: National Academy of Sciences.
- Gruen, A. (2012). Development and Status of Image Matching in Photogrammetry. *The Photogrammetric Record*, 22.
- Gruen, A. W. (1985). ADAPTIVE LEAST SQUARES CORRELATION: A POWERFUL IMAGE MATCHING TECHNIQUE. *S Afr J of Photogrammetry, Remote Sensing and Cartography*, 13.
- Hannah, M. (1988). Digital Stereo Image Matching Techniques. *International Archives of Photogrammetry and Remote Sensing*, 14.
- Harlyn Baker, H. (1982). Depth from Edge and Intensity Based Stereo. 100.
- Hernandez Orallo, E. (s.f.). *El Lenguaje Unificado de Modelado (UML)*.
- Hsieh, Y. C., Perlant, F., & McKeown, D. M. (1990). Recovering 3D Information from Complex Aerial Imagery. *IEEE*, 11.
- IDEAM, IGAC y CORMAGDALENA. (2008). *Mapa de Cobertura de la Tierra Cuenca Magdalena-Cauca: Metodología CORINE Land Cover adaptada para Colombia a escala 1:100.000*. Instituto de Hidrología, Meteorología y Estudios Ambientales. Bogotá, D.C.: Instituto Geográfico Agustín Codazzi y Corporación Autónoma Regional del río Grande de La Magdalena.
- Izaurieta, F., & Saavedra, C. (n.d.). Redes Neuronales Artificiales. *Departamento de Física, Universidad de Concepcion, Chile*, 15.
- Jancso, T., & Melykuti, G. (2011). Comparison of Digital Terrain Models Gained by Different Technologies. *Spatial Data Mining and Geographical Knowledge Services (ICSDM)*, 6.



- Jiang, L., Xie, H., & Pan, B. (2014). Speeding up digital image correlation computation using the integral image technique. *Optics and Lasers in Engineering*, 6.
- Lang, F., & Forstner, W. (1995). Matching Techniques. Universidad de Bonn.
- Larman, C. (2005). *Applying UML and Patterns: an introduction to object-oriented analysis and design and iterative development*. Prentice Hall PTR.
- Lecumberry, F. (n.d.). Calculo de disparidad en imagenes estereo, una comparacion. *III Workshop de Computacion Grafica, Imagenes y Visualizacion*, 12.
- Lee, H.-Y., Kim, T., Park, W., & Lee, H. K. (2003). Extraction of digital elevation models from satellite stereo images through stereo matching based on epipolarity and scene geometry. *Image and Vision Computing*, 8.
- Li, Z., Zhu, Q., & Gold, C. (2004). *DIGITAL TERRAIN MODELING. Principles and Methodology*. Florida: CRC Press.
- Lizana, C. (2008). Catedra de fotogrametria. En J. A. Perez Alvares, *Apuntes de FOTOGRAMETRIA II* (pág. 20).
- Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Universidad Tecnológica Nacional.
- Maune, D. F. (2011). *Digital Elevation Model (DEM) Whitepaper NRCS High Resolution Elevation Data*. Texas.
- McKeown, J. D., & Hsieh, Y. C. (1992). Hierarchical Waveform Matching: A New Feature-Based Stereo Technique. *IEEE*, 7.



- Muller, J.-P., Mandanayake, A., Moroney, C., Davies, R., Diner, D. J., & Paradise, S. (2002). MISR Stereoscopic Image Matchers: Techniques and Results. *IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING*, 13.
- Nurminen, K., Karjalainen, M., Yu, X., Hyypä, J., & Honkavaara, E. (2013). Performance of dense digital surface models based on image matching in the estimation of plot-level forest variables. *Journal of Photogrammetry and Remote Sensing*, 12.
- Sarría, F. A. (2006). *Temario Sistemas de Información Geográfica*. Murcia: Universidad de Murcia.
- Sohn, G., & Dowman, I. (2007). Data fusion of high-resolution satellite imagery and LiDAR data for automatic building extraction. *ScienceDirect*, 21.
- Zhong, X., Peng, X., Zhong, X., & Dong, X. (2012). Multi-Channel with RBF Neural Network Aggregation Based on Disparity Space for Color Image Stereo Matching. *IEEE fifth International Conference on Advanced Computational Intelligence(ICACI)*, 6.
- Zhou, G., Song, C., Simmers, J., & Cheng, P. (2004). Urban 3D GIS From LiDAR and digital aerial images. *Computers & Geosciences*, 9.



Anexo1



INSTITUTO GEOGRÁFICO AGUSTÍN CODAZZI 28-04-2016 09:06
 PAZ Al Contestar, Cite Nr.:8002016EE4321-01 - F:3 - A:3
 ORIGEN: SUBDIRECCION DE GEOGRAFIA Y CARTOGRAFIA LEON RIVERA
 DESTINO: UNIVERSIDAD DISTRITAL FRANCISCO JOSE DE CALDAS/O
 ASUNTO: E/R. 8002016ER3993 DEL 31 DE MARZO DE 2016 Y 800201
 OBS: ANEXO TRES (3) DVD Y TRES (3) FOLIOS

3090/

Bogotá,

Doctor
 ALEXIS ADAMY ORTIZ MORALES
 Director Centro Relaciones Interinstitucionales
 UNIVERSIDAD DISTRITAL FRANCISCO JOSÉ DE CALDAS
 Carrera 7 No. 40-53 Piso 3°
 Bogotá, D.C.

Asunto: Suministro de información cartográfica

Respetado doctor Ortiz Morales:

En atención al requerimiento del asunto y con el fin de apoyar las actividades que adelanta el Señor YEISON JAVIER CAJAMARCA, estudiante de la Maestría en Ciencias de la Información y las comunicaciones de la Facultad de Ingeniería, quien se encuentra desarrollando su tesis de grado titulada: “EVALUACIÓN DE UNA METODOLOGÍA PARA LA GENERACIÓN DE MODELOS DIGITALES DE TERRENO A PARTIR DE LA ESTEREOFOTOGRAFÍA DIGITAL APLICANDO EL MODELO DE CORRELACIÓN POR MÍNIMOS CUADRADOS MEDIANTE UNA RED NEURONAL ARTIFICIAL”, me permito hacer entrega de la siguiente información disponible, así:

- Recorte de MDT con sus respectivos metadatos, de la zona correspondientes a las planchas 115III B1 y 115III B3 a escala 1:10.000 en formato IMG.
- Ochenta y un (81) aerofotografías digitales en formato TIFF.

Formato	Vuelo	Aerofotografías	Cantidad
TIFF	11503024032010	1443, 1444, 1445, 1446, 1447, 1448, 1449, 1450, 1451, 1466, 1467, 1468, 1469, 1470, 1471, 1472, 1473, 1474, 1475, 1476, 1477, 1478, 1479, 1532, 1533, 1534, 1535, 1536, 1537, 1538, 1539, 1540, 1541, 1542, 1543, 1544	36
	11503005062012	376, 377, 378, 379, 380, 381, 382, 383, 384, 385, 386, 387, 388, 442, 443, 444, 445, 446, 447, 448, 449	21
	11503026092012	191, 192, 193, 194, 195, 196, 197, 198, 199, 200, 201, 202	12
	11503012012013	366, 367, 368, 369, 370, 371, 372, 373, 374, 375, 376, 377	12
TOTAL			81



80 AÑOS
1935 - 2015

IGAC
INSTITUTO GEOGRÁFICO
AGUSTÍN CODAZZI



TODOS POR UN
NUEVO PAÍS
PAZ EQUIDAD EDUCACIÓN

IGAC
INSTITUTO GEOGRÁFICO
AGUSTÍN CODAZZI

80 AÑOS
1935 - 2015

Así mismo, envío las Licencias de Usos No. 3880-2016 y 3881-2016 de la información suministrada, las cuales deben ser debidamente firmadas y regresadas al Instituto Geográfico Agustín Codazzi –Subdirección de Geografía y Cartografía, por correo certificado o al siguiente correo electrónico mbeltran@igac.gov.co.

Cordial saludo,

FERNANDO LEÓN RIVERA
Subdirector de Geografía y Cartografía

Anexo: Tres (3) DVD y Tres (3) folios.

Revisó: Manuel Guillermo Beltrán.
Proyectó: Samuel Guerrero Velásquez.

Radicado No. 8002016ER3993 del 31 de Marzo de 2016
8002016ER4910 del 14 de Abril de 2016

Cantidad	Descripción	Valor	Importe
10	112002012010		
11	112002012011		
12	112002012012		
13	112002012013		
14	112002012014		
15	TOTAL		



LICENCIA DE USO PARA PRODUCTOS DE PROPIEDAD DEL INSTITUTO GEOGRÁFICO AGUSTIN CODAZZI No. 3880-2016

EL INSTITUTO GEOGRÁFICO AGUSTÍN CODAZZI establece los siguientes términos y condiciones para el uso y acceso a la información geográfica y cartográfica en el ámbito de la ICDE y en cumplimiento de la política nacional de Información Geográfica (IG)- en adelante IGAC -, en su calidad de titular del derecho de autor y custodio del Recorte del MDT con sus respectivos metadatos, de la zona correspondientes a las planchas 115III B1 y 115III B3 a escala 1:10.000 en formato IMG., - en adelante PRODUCTO - autoriza su uso sin exclusividad a la UNIVERSIDAD DISTRITAL FRANCISCO JOSÉ DE CALDAS - en adelante LICENCIATARIO - para ser utilizado únicamente para los siguientes fines: Misional para apoyar las actividades que adelantan los estudiantes de la Maestría en Ciencias de la Información y las comunicaciones de la Facultad de Ingeniería.. El LICENCIATARIO en el presente documento se compromete para con el IGAC a: 1.- Respetar los derechos de autor, y brindar el apropiado crédito de titularidad al IGAC (contemplando lo siguiente: titular, año de edición y publicación, tipo de información, escala y/o resolución espacial). Todo ello con sujeción a las normas especiales civiles y penales que regulan el derecho de autor. 2.- No copiar, vender, comercializar, distribuir y transferir, en forma alguna, el PRODUCTO proporcionado, por cualquier medio conocido o por conocer. 3.- No eliminar, ocultar o alterar los avisos de propiedad intelectual del IGAC, tanto de derecho de autor como de propiedad industrial, que se adjunte o contenga el PRODUCTO. 4.- No incluir dentro del PRODUCTO logosímbolos, leyendas ni publicidad alguna sin autorización expresa del IGAC. 5.- No realizar modificación alguna a la información contenida en el PRODUCTO, sin autorización expresa y escrita del IGAC. 6.- Responder por la incorrecta, indebida e ilegal utilización que LICENCIATARIO realice, de manera propia, ó mediante tercera persona bajo su aprobación, del PRODUCTO. En consecuencia, el IGAC no será responsable de reclamación, daño general, especial, incidental o consecuente que se derive del uso del mismo, e incluso de la pérdida y/o los perjuicios causados por el LICENCIATARIO, directa o indirectamente, de la utilización del PRODUCTO, aunque el IGAC haya sido puesto sobre aviso acerca de tales daños. En general, sobre los eventos expuestos, el IGAC no podrá ser demandado judicialmente, sin embargo, sí podrá ejercer las acciones legales conducentes en contra del LICENCIATARIO. 7.- No ceder los derechos y obligaciones derivados del presente documento a persona natural y/o jurídica, sin previo consentimiento expreso y escrito del IGAC. 8.- Ni el LICENCIATARIO ni su personal podrán revelar información confidencial alguna de propiedad del IGAC relacionada en la presente licencia de uso, sin el previo consentimiento por escrito del IGAC. El LICENCIATARIO utilizará los medios necesarios para que su personal guarde la debida reserva sobre la mencionada información y responderá por el uso indebido y por toda violación que afecte los derechos del IGAC. La confidencialidad será durante la vigencia de la presente licencia y después de la terminación de la misma. 9.- Si necesita utilizar el PRODUCTO, ó su información contenida, para un fin diferente al relacionado en el presente documento, solicitará previo permiso al IGAC. 10.- El IGAC garantiza que el PRODUCTO otorgado cumple con las características descritas en la presente licencia y aquellos para los cuales fue diseñado Posterior a la entrega, todo el riesgo referente al uso del PRODUCTO es responsabilidad del LICENCIATARIO. En todo caso, el IGAC no se hace responsable de la calidad de los trabajos, obras o investigaciones realizadas, posteriormente, con fundamento en la información y los datos suministrados en el PRODUCTO, facilitados mediante la presente licencia de uso. Igualmente, el IGAC no ofrece garantía alguna sobre calidad, rendimiento o idoneidad para fines concretos de los mismos. En todo evento, el LICENCIATARIO se compromete a advertir cualquier imprecisión de la información y/o productos suministrados, para lo cual el IGAC podrá verificar, modificar y comunicar cualquier asunto al respecto. 11.- Las responsabilidades que mediante esta licencia contraen el IGAC y el LICENCIATARIO, no las hace solidariamente responsables ante terceros. En consecuencia, cada parte será responsable de las obligaciones que resulten como consecuencia de la presente licencia. 12.- El IGAC puede rescindir la presente licencia, ante el incumplimiento de las obligaciones de la misma, para lo cual notificará al LICENCIATARIO de su decisión. Lo anterior, sin perjuicio de los demás mecanismos legales otorgados para la indemnización de los perjuicios causados en virtud de la infracción de alguno de los términos y condiciones de esta licencia. 13.- La vigencia de la presente licencia de uso del PRODUCTO, se inicia con la firma del presente documento, donde el mismo se otorga con una fecha de actualización expresa, y durará hasta que exista una nueva actualización del PRODUCTO. En constancia suscribe el presente documento a los 21 día(s) del mes de Abril de 2016.

Nombre Licenciatario	UNIVERSIDAD DISTRITAL FRANCISCO JOSÉ DE CALDAS		Identificación
Nombre Representante Legal			Identificación
Dirección			
Teléfono Contacto		Correo Electrónico Contacto	
FIRMA			



PARAMETROS		Anexo 2 UMBRAL					COEF CORRELACION	ERROR ACUM
		NODO 0	NODO 1	NODO 2	NODO 3	NODO 4		
Iteraciones	500							
taza de aprendizaje	0,3							
momentum	0,2	-0,52869376	10,08369092	-9,73228383	-9,77578136	-5,05378775	0,7784	0,0062069
Iteraciones	500							
taza de aprendizaje	0,4							
momentum	0,2	-0,50731172	10,28869201	-9,19673791	-5,37455310	-9,25557407	0,7712	0,008769
Iteraciones	500							
taza de aprendizaje	0,5							
momentum	0,2	0,04864314	11,27604322	-8,86197814	-5,75886880	-9,55139948	0,7855	0,009834
Iteraciones	500							
taza de aprendizaje	0,6							
momentum	0,2	0,97073087	-25,44138048	-59,51687876	-4,94307829	-28,72158824	0,8174	0,010087
Iteraciones	500							
taza de aprendizaje	0,7							
momentum	0,2	1,00000013	-14,75760242	-17,71096049	-59,80694325	-58,56469052	0,8203	0,01019
Iteraciones	500							
taza de aprendizaje	0,8							
momentum	0,2	0,77640935	-3,06251175	-9,20903980	-2,69166978	-79,69960021	0,7898	0,013128



Iteraciones	500							
taza de aprendizaje	0,9							
momentum	0,2	0,82093902	-3,976533053	-10,53667458	-85,70854020	-3,24410669	0,784	0,0147693
Iteraciones	500							
taza de aprendizaje	0,1							
momentum	0,3	0,82093902	-3,62637289	-10,53667458	-85,70854020	-3,24410669	0,7840	0,047742
Iteraciones	500							
taza de aprendizaje	0,2							
momentum	0,3	-0,52470899	9,14675668	-8,99069298	-9,01721691	-4,72824919	0,7857	0.0057159
Iteraciones	500							
taza de aprendizaje	0,3							
momentum	0,3	-0,50635209	9,83601254	-8,7628007456	-9,22530933	-5,14556225	0,7749	0,0063987
Iteraciones	500							
taza de aprendizaje	0,4							
momentum	0,3	-0,54167147	10,95656067	-9,13164572	-5,55455739	-9,19226759	0,7641	0,0072069
Iteraciones	500							
taza de aprendizaje	0,5							
momentum	0,3	0,03184746	12,79805595	-9,865409547	-5,86956051	-9,37485119	0,7924	0,0081755
Iteraciones	500							
taza de aprendizaje	0,6							
momentum	0,3	-0,89496460	-29,94233458	-22,55769926	41,45288363	-54,47837231	0,8169	0,0137514
Iteraciones	500							
taza de aprendizaje	0,7							
Momentum	0,3	0,82441586	-3,97798940	-78,95590990	-4,05864173	-3,56091779	0,7826	0,0122805



Iteraciones	500							
taza de aprendizaje	0,8							
Momentum	0,3	0,82629435	-86,41730313	-3,62171371	-10,54193262	-3,23293823	0,7836	0,0142761
Iteraciones	500							
taza de aprendizaje	0,9							
momentum	0,3	0,63072064	-3,37972916	-3,56869042	-3,28237082	-2,52307919	0,5067	0,0235757
Iteraciones	500							
taza de aprendizaje	0,1							
momentum	0,4	-0,53452605	8,44270320	-8,53891184	-8,55194422	-4,34501531	0,802	0,0051987
Iteraciones	500							
taza de aprendizaje	0,2							
momentum	0,4	-0,52707263	9,41230897	-9,11998659	-9,15230121	-4,83773201	0,7814	0,0059094
Iteraciones	500							
taza de aprendizaje	0,3							
momentum	0,4	-0,50804955	10,28749509	-9,19529895	-9,25717068	-5,35551684	0,7712	0,0066893
Iteraciones	500							
taza de aprendizaje	0,4							
momentum	0,4	-0,10752942	12,15179280	-9,16351277	-5,74211963	-9,28237835	0,7959	0,0076282
Iteraciones	500							
taza de aprendizaje	0,5							
momentum	0,4	0,35073588	14,6318036692	-9,30117806	-5,92939900	-9,51144121	0,792	0,0089253
Iteraciones	500							
taza de aprendizaje	0,6							
momentum	0,4	0,82755447	-4,19062847	-78,63811833	-3,61804407	-3,88264631	0,7822	0,0119071



Iteraciones	500							
taza de aprendizaje	0,7							
Momentum	0,4	0,85285434	-4,53212353	-85,76230046	-4,04631228	-4,47302215	0,778	0,0140944
Iteraciones	500							
taza de aprendizaje	0,8							
momentum	0,4	-0,99520800	-43,95007891	-19,96948178	-4,98871943	95,53363233	0,7717	0,0223257
Iteraciones	500							
taza de aprendizaje	0,9							
momentum	0,4	-0,87672901	-5,59202467	-15,75977918	112,52407623	5,93136935	0,7723	0,0278704
Iteraciones	500							
taza de aprendizaje	0,1							
momentum	0,5	-0,51763704	8,63205217	-8,67855295	-8,67160009	-4,51779835	0,7964	0,0053206
Iteraciones	500							
taza de aprendizaje	0,2							
momentum	0,5	-0,52320896	9,73754569	-9,22344436	-9,25869577	-5,02174833	0,7767	0,0061814
Iteraciones	500							
taza de aprendizaje	0,3							
momentum	0,5	-0,01032407	11,01022547	-8,82698397	-5,67450730	-9,48648917	0,7866	0,0071348
Iteraciones	500							
taza de aprendizaje	0,4							
momentum	0,5	0,31166070	13,55787951	-9,21020777	-8,16935351	-5,90160292	0,7925	0,0083327
Iteraciones	500							
taza de aprendizaje	0,5							
momentum	0,5	0,86116644	-3,88290191	-16,76413544	-3,29991919	-78,23451265	0,7797	0,0117062



Iteraciones	500							
taza de aprendizaje	0,6							
Momentum	0,5	-0,66754154	83,72214367	-4,74135028	-18,15688194	-4,32332742	0,7788	0,016126
Iteraciones	500							
taza de aprendizaje	0,7							
momentum	0,5	-0,94176011	-13,56340714	-4,76590676	107,81976996	5,03446597	0,7774	0,0194806
Iteraciones	500							
taza de aprendizaje	0,8							
momentum	0,5	-0,70609164	-15,08952345	118,00196222	-5,35290492	-5,64037172	0,7761	0,0241702
Iteraciones	500							
taza de aprendizaje	0,9							
momentum	0,5	-0,99940832	132,17182301	-5,91604907	-6,28521876	-16,96412211	0,7704	0,030306
Iteraciones	500							
taza de aprendizaje	0,1							
momentum	0,6	-0,58592875	8,96905985	-4,81678352	-8,50938221	-4,95974334	0,7873	0,0055238
Iteraciones	500							
taza de aprendizaje	0,2							
momentum	0,6	-0,50952356	10,26862222	-9,18178668	-9,23565119	-5,41475095	0,7711	0,0065666
Iteraciones	500							
taza de aprendizaje	0,3							
momentum	0,6	0,33433283	13,60560727	-9,10094934	-9,46835504	-5,99471865	0,7996	0,007817
Iteraciones	500							
taza de aprendizaje	0,4							
momentum	0,6	0,33433283	13,60560727	-9,10094934	-9,46835504	-5,99471865	0,7827	0,0118918



Iteraciones	500							
taza de aprendizaje	0,5							
Momentum	0,6	-1,00540674	-4,43572065	91,54567799	-4,87621464	-4,89458634	0,7789	0,0152119
Iteraciones	500							
taza de aprendizaje	0,6							
momentum	0,6	0,69416463	-2,84427241	-3,72786138	-3,72655641	-3,73241280	0,4912	0,0227818
Iteraciones	500							
taza de aprendizaje	0,7							
momentum	0,6	0,75645868	-3,93169857	-13,37097048	-3,20498261	-3,72177746	0,5478	0.0255186
Iteraciones	500							
taza de aprendizaje	0,8							0,029369
momentum	0,6	0,82285003	-4,14232819	-4,08990721	-14,86231043	-4,41751659	0,5203	7
Iteraciones	500							
taza de aprendizaje	0,9							
momentum	0,6	1,69293704	17,45825228	-45,27718597	-61,00130526	21,29556918	-0,802	0,0703158
Iteraciones	500							
taza de aprendizaje	0,1							
momentum	0,7	-0,58548888	9,48414147	-5,01420137	-8,73549582	-5,21068288	0,7792	0,0058623
Iteraciones	500							
taza de aprendizaje	0,2							
momentum	0,7	-0,08336787	12,42075633	-9,19413437	-5,86294356	-9,28001188	0,7981	0,0072758
Iteraciones	500							
taza de aprendizaje	0,3							
momentum	0,7	0,87139709	-4,68571831	-74,25732362	-24,65528973	-4,09689555	0,78	0,0115861



Iteraciones	500							
taza de aprendizaje	0,4							
Momentum	0,7	0,74352713	-94,78828075	-3,08611098	-3,85934594	-3,27643537	0,5265	0,0203218
Iteraciones	500							
taza de aprendizaje	0,5							
momentum	0,7	7,32949204	-3,87377395	-3,87377395	-3,75324790	-4,40443975	0,4849	0,0238414
Iteraciones	500							
taza de aprendizaje	0,6							
momentum	0,7	0,92571764	-6,19861385	-6,09261910	-4,78973858	-5,82429252	0,3308	0,0277946
Iteraciones	500							
taza de aprendizaje	0,7							
momentum	0,7	1,32403726	-18,38000834	16,19191682	17,030797990268	-19,82878209	-0,8038	0,0243863
Iteraciones	500							
taza de aprendizaje	0,8			7,42783971010268				
momentum	0,7	5,07569403	-18,0499412380	0	-31,18126015	-23,27579335	-0,7079	0,2881541
Iteraciones	500							
taza de aprendizaje	0,9							
momentum	0,7	ERROR	ERROR	ERROR	ERROR	ERROR	ERROR	ERROR
Iteraciones	500							
taza de aprendizaje	0,1							
momentum	0,8	-0,36264875	10,24184933	-8,73903362	-5,38248194	-5,80675670	0,7727	0,0065143
Iteraciones	500							
taza de aprendizaje	0,2							
momentum	0,8	0,84247437	-4,12615055	-73,07045015	4,60060335	-4,65894750	0,7797	0,0112314



Iteraciones	500							
taza de aprendizaje	0,3							
Momentum	0,8	7,325345434	-3,8765365365	-3,87887875	-3,755676460	-4,445465675	0,4905	0,0214928
Iteraciones	500							
taza de aprendizaje	0,4							
momentum	0,8	0,77797081	-4,75584054	-4,19981501	-4,17855015	-4,73510863	0,4899	0,0264998

Tabla 4 Datos obtenidos en el experimento con una capa y 4 neuronas



PARAMETROS		UMBRAL												COEF CORRELACION	ERROR ACUM	
		NODO 0	NODO 1	NODO 2	NODO 3	NODO 4	NODO 5	NODO 6	NODO 7	NODO 8	NODO 9	NODO 10	NODO 11			NODO 12
taza de aprendizaje	0,4															
momentum	0,2															
Iteraciones	500	-0,6464	-56,4610	-5,4671	-26,8587	-11,0753	-2,9059	-2,9062	-2,9053	-2,9053	-2,9056	-2,9057	-2,9066	-2,9066	0,8409	0,0056
taza de aprendizaje	0,5															
momentum	0,2															
Iteraciones	500	-0,6218	-64,1523	-5,4142	-12,5692	-11,8207	-2,9663	-2,9664	-2,9661	-2,9661	-2,9662	-2,9662	-2,9665	-2,9664	0,8405	0,0061
taza de aprendizaje	0,6															
momentum	0,2															
Iteraciones	500	-0,5913	-59,1943	-6,0998	-41,8000	-13,4865	-3,0259	-3,0260	-3,0259	-3,0259	-3,0259	-3,0259	-3,0260	-3,0260	0,8404	0,0067
taza de aprendizaje	0,7															
momentum	0,2															
Iteraciones	500	-0,5582	-61,4612	-10,6894	-44,7546	-14,0323	-3,0851	-3,0851	-3,0850	-3,0850	-3,0850	-3,0851	-3,0851	-3,0851	0,8404	0,0075
taza de aprendizaje	0,8															
momentum	0,2															
Iteraciones	500	-0,5176	-64,3766	-10,3642	-45,6057	-15,9275	-3,1486	-3,1485	-3,1485	-3,1485	-3,1485	-3,1485	-3,1485	-3,1486	0,8407	0,0083
taza de aprendizaje	0,9															
momentum	0,2															
Iteraciones	500	-0,4691	-66,9781	-10,0301	-45,2189	-17,8505	-3,2186	-3,2186	-3,2186	-3,2186	-3,2186	-3,2186	-3,2186	-3,2186	0,8411	0,0093



taza de aprendizaje	0,1															
momentum	0,3															
Iteraciones	500	-0,6770	-7,2219	-3,7993	-37,3317	-7,0782	-2,6214	-2,6222	-2,6193	-2,6204	-2,6212	-2,6214	-2,6238	-2,6231	0,8447	0.00450
taza de aprendizaje	0,2															
momentum	0,3															
Iteraciones	500	-0,6728	-46,9121	-8,7712	-9,1569	-4,6028	-2,8005	-2,8005	-2,8054	-2,8057	-2,8017	-2,8034	-2,7962	-2,8000	0,8429	0,0049
taza de aprendizaje	0,3															
momentum	0,3															
Iteraciones	500	-0,6591	-52,5751	-8,0816	-27,2501	-10,0100	-2,8758	-2,8751	-2,8771	-2,8772	-2,8763	-2,8762	-2,8743	-2,8753	0,8413	0,0053
taza de aprendizaje	0,4															
momentum	0,3															
Iteraciones	500	-0,6345	-61,9153	-5,3255	-12,0126	-9,5985	-2,9421	-2,9423	-2,9416	-2,9416	-2,9419	-2,9418	2,9426	-2,9423	0,8406	0,0058
taza de aprendizaje	0,5															
momentum	0,3															
Iteraciones	500	-0,6058	-67,6648	5,6288	-13,2940	-14,4798	-3,0030	-3,0030	-3,0029	-3,0029	-3,0029	-3,0029	-3,0031	-3,0031	0,8402	0,0064
taza de aprendizaje	0,6															
momentum	0,3															
Iteraciones	500	-0,5726	-60,9729	-9,7360	-45,2152	-14,0681	3,0634	-3,0634	-3,0633	-3,0633	-3,0633	-3,0634	-3,0635	-3,0634	0,8403	0,0071
taza de aprendizaje	0,7															
momentum	0,3															
Iteraciones	500	-0,5346	-63,9685	-10,0565	-47,4699	-16,0942	-3,1243	-3,1243	-3,1242	-3,1242	-3,1243	-3,1242	-3,1243	-3,1243	0,8404	0,0078



taza de aprendizaje	0,8															
momentum	0,3															
Iteraciones	500	-0,4897	-67,2711	-9,6997	-47,7405	-18,4298	-3,1890	-3,1890	-3,1890	-3,1890	-3,1890	-3,1890	-3,1890	-3,1890	0,8407	0,0087
taza de aprendizaje	0,9															
momentum	0,3															
Iteraciones	500	-0,4363	-69,1505	-7,5443	-47,6250	-20,4616	-3,2604	-3,2604	-3,2604	-3,2604	-3,2604	-3,2604	-3,2604	-3,2604	0,8413	0,0098
taza de aprendizaje	0,1															
momentum	0,4															
Iteraciones	500	-0,6752	-7,7691	-3,9608	-39,1982	-7,1061	-2,6915	-2,6918	-2,6909	-2,6925	-2,6914	-2,6923	-2,6920	-2,6931	0,8444	0,0046
taza de aprendizaje	0,2															
momentum	0,4															
Iteraciones	500	-0,6696	-49,8152	-8,4308	-9,6726	-4,7526	-2,8439	-2,8432	-2,8471	-2,8472	-2,8448	-2,8457	-2,8410	-2,8434	0,8423	0,0050
taza de aprendizaje	0,3															
momentum	0,4															
Iteraciones	500	-0,6476	-58,6382	-5,2738	-10,9146	-9,4760	-2,9209	-2,9211	-2,9201	-2,9201	-2,9206	-2,9205	-2,9215	-2,9211	0,8409	0,0055
taza de aprendizaje	0,4															
momentum	0,4															
Iteraciones	500	-0,6167	-65,8478	-5,4459	-12,8353	-12,5889	-2,9886	-2,9887	-2,9882	-2,9882	-2,9884	-2,9884	-2,9888	-2,9887	0,8403	0,0061
taza de aprendizaje	0,5															
momentum	0,4															
Iteraciones	500	-0,5816	-64,2395	-5,7942	-39,1899	-14,0982	-3,0527	-3,0527	-3,0526	-3,0526	-3,0527	-3,0527	-3,0528	-3,0528	0,8401	0,0067



taza de aprendizaje	0,6															
momentum	0,4															
Iteraciones	500	-0,5439	-62,3286	-10,0501	-50,1853	-16,1426	-3,1156	-3,1156	-3,1155	-3,1155	-3,1155	-3,1156	-3,1156	-3,1156	0,8403	0.00750
taza de aprendizaje	0,7															
momentum	0,4															
Iteraciones	500	-0,4982	-66,4544	-8,2958	-50,8978	-18,9040	-3,1812	-3,1812	-3,1811	-3,1811	-3,1811	-3,1811	-3,1812	-3,1812	0,8406	0,0084
taza de aprendizaje	0,8															
momentum	0,4															
Iteraciones	500	-0,4459	-69,8085	-9,5999	-49,7283	-21,0188	-3,2501	-3,2501	-3,2501	-3,2501	-3,2501	-3,2501	-3,2501	-3,2501	0,8411	0,0094
taza de aprendizaje	0,9															
momentum	0,4															
Iteraciones	500	0,3852	-74,6313	-21,0328	-43,7267	-23,1626	-3,3309	-3,3308	-3,3308	-3,3309	-3,3309	-3,3308	-3,3308	-3,3309	0,8417	0,0106
taza de aprendizaje	0,1															
momentum	0,5															
Iteraciones	500	-0,6737	-8,3612	-4,1515	-41,5772	-7,2218	-2,7673	-2,7673	-2,7675	-2,7693	-2,7674	2,7686	-2,7668	-2,7688	0,8441	0,0046
taza de aprendizaje	0,2															
momentum	0,5															
Iteraciones	500	-0,6613	-53,4965	-7,8305	-10,3387	-5,0412	-2,8960	-2,8956	-2,8976	-2,8974	-2,8964	-2,8967	-2,8946	-2,8956	0,8417	0,0052
taza de aprendizaje	0,3															
momentum	0,5															
Iteraciones	500	0,6281	-63,0140	-5,3288	-12,2094	-9,6645	-2,9764	-2,9766	-2,9759	-2,9758	-2,9762	-2,9761	-2,9769	-2,9766	0,8405	0,0058



taza de aprendizaje	0,4															
momentum	0,5															
Iteraciones	500	-0,5905	-70,5323	-5,6095	-13,8543	-15,9409	-3,0473	-3,0473	-3,0471	-3,0471	-3,0472	-3,0472	-3,0474	-3,0474	0,8400	0,0065
taza de aprendizaje	0,5															
momentum	0,5															
Iteraciones	500	-0,5468	-61,8137	-6,1240	-50,9125	-16,2065	-3,1174	-3,1175	-3,1174	-3,1174	-3,1174	-3,1174	-3,1175	-3,1175	0,8403	0,0073
taza de aprendizaje	0,6															
momentum	0,5															
Iteraciones	500	-0,4991	-64,8206	-9,6229	-54,4541	-19,3240	-3,1872	-3,1872	-3,1872	-3,1872	-3,1872	-3,1872	-3,1872	-3,1872	0,8405	0,0082
taza de aprendizaje	0,7															
momentum	0,5															
Iteraciones	500	-0,4415	-68,5877	-21,4711	-53,9282	-10,4628	-3,2636	-3,2636	-3,2636	-3,2636	-3,2636	-3,2636	-3,2636	-3,2636	0,8411	0,0093
taza de aprendizaje	0,8															
momentum	0,5															
Iteraciones	500	-0,3751	-74,8328	-22,5045	-48,3621	-23,5187	-3,3495	-3,3495	-3,3495	-3,3495	-3,3495	-3,3495	-3,3495	-3,3495	0,8419	0,0105
taza de aprendizaje	0,9															
momentum	0,5															
Iteraciones	500	-0,3049	-69,0750	-6,7157	-53,5949	-27,3963	-3,4339	-3,4339	-3,4339	-3,4339	-3,4339	-3,4339	-3,4339	-3,4339	0,8424	0,0118
taza de aprendizaje	0,1															
momentum	0,6															
Iteraciones	500	-0,5885	-36,4756	-5,0982	-30,6468	-7,7219	-3,0106	-3,0108	-3,0104	-3,0105	-3,0105	-3,0107	-3,0109	-3,0109		0,0048



taza de aprendizaje	0,2															
momentum	0,6															
Iteraciones	500	-0,6433	-57,9280	-5,2297	-19,7465	-10,9799	-2,9600	-2,9604	-2,9591	-2,9591	-2,9597	-2,9597	-2,9609	-2,9603	0,8410	0,0054
taza de aprendizaje	0,3															
momentum	0,6															
Iteraciones	500	-0,5981	-68,6808	-5,5090	-13,4133	-14,0685	-3,0456	-3,0457	-3,0454	-3,0454	-3,0455	-3,0455	-3,0458	-3,0457	0,8402	0,0062
taza de aprendizaje	0,4															
momentum	0,6															
Iteraciones	500	-0,5885	-36,4756	-5,0982	-30,6468	-7,7219	-3,0106	-3,0108	-3,0104	-3,0105	-3,0105	-3,0107	-3,0109	-3,0109		0,0071
taza de aprendizaje	0,5															
momentum	0,6															
Iteraciones	500	-0,4909	-64,0512	-9,4914	-56,7590	-19,9693	-3,2060	-3,2060	-3,2060	-3,2060	-3,2060	-3,2060	-3,2060	-3,2060	0,8406	0,0081
taza de aprendizaje	0,6															
momentum	0,6															
Iteraciones	500	-0,4230	-69,3902	-21,3953	-55,9206	-17,4217	-3,2967	-3,2967	-3,2967	-3,2967	-3,2967	-3,2967	-3,2967	-3,2967	0,8413	0,0093
taza de aprendizaje	0,7															
momentum	0,6															
Iteraciones	500	-0,3443	-71,9013	-21,8331	-51,1415	-22,2389	-3,3935	-3,3934	-3,3934	-3,3935	-3,3935	-3,3934	-3,3934	-3,3935	0,8421	0,0107
taza de aprendizaje	0,8															
momentum	0,6															
Iteraciones	500	-0,2603	-73,4691	-22,8252	-44,8825	-32,6507	-3,4969	-3,4968	-3,4968	-3,4968	-3,4969	-3,4968	-3,4968	-3,4969	0,8431	0,0121



taza de aprendizaje	0,9															
momentum	0,6															
Iteraciones	500	-0,1786	-76,1214	-7,6308	-53,2112	-22,7191	-3,6063	-3,6062	-3,6062	-3,6062	-3,6062	-3,6062	-3,6062	-3,6063	0,8437	0,0139
taza de aprendizaje	0,1															
momentum	0,7															
Iteraciones	500	-0,6635	-49,6544	-8,0722	-9,6621	-4,7233	-2,9244	-2,9240	-2,9267	-2,9267	-2,9268	-2,9250	-2,9258	-2,9225	0,8424	0,0050
taza de aprendizaje	0,2															
momentum	0,7															
Iteraciones	500	-0,6086	-61,5914	-5,4037	-30,6911	-12,4729	-3,0412	-3,0414	-3,0409	-3,0409	-3,0410	-3,0411	-3,0416	-3,0414	0,8405	0,0059
taza de aprendizaje	0,3															
momentum	0,7															
Iteraciones	500	-0,5445	-59,8065	-5,7431	-52,4691	-16,2419	-16,241	-3,1414	-3,1411	-3,1412	-3,1412	-3,1413	-3,1414	-3,1414	0,8404	0,0070
taza de aprendizaje	0,4															
momentum	0,7															
Iteraciones	500	-0,4702	-64,6598	-9,3106	-57,9382	-21,2378	-3,2425	-3,2425	-3,2425	-3,2425	-3,2425	-3,2425	-3,2425	-3,2425	0,8409	0,0082
taza de aprendizaje	0,5															
momentum	0,7															
Iteraciones	500	-0,3815	-70,0803	-22,8727	-57,6673	-25,2479	-3,3547	-3,3547	-3,3547	-3,3547	-3,3547	-3,3547	-3,3547	-3,3547	0,8417	0,0097
taza de aprendizaje	0,6															
momentum	0,7															
Iteraciones	500	-0,2817	-72,8942	-23,2285	-51,5110	-33,2534	-3,4789	-3,4789	-3,4789	-3,4789	-3,4789	-3,4789	-3,4789	-3,4789	0,8428	0,0114



taza de aprendizaje	0,7																
momentum	0,7																
Iteraciones	500	-0,1792	-72,9028	-23,7056	-52,4350	-37,8304	-3,6110	-3,6110	-3,6110	-3,6110	-3,6110	-3,6110	-3,6110	-3,6110	0,8438	0,0133	
taza de aprendizaje	0,8																
momentum	0,7																
Iteraciones	500	-0,0818	-74,1313	-7,9116	-61,9763	-20,7929	-3,7495	-3,7495	-3,7494	-3,7495	-3,7495	-3,7495	-3,7496	-3,7497	0,8443	0,0156	
taza de aprendizaje	0,9																
momentum	0,7																
Iteraciones	500	-0,0170	-63,2557	-7,7737	-46,1729	-53,3009	-3,9014	-3,9014	-3,9014	-3,9014	-3,9014	-3,9014	-3,9014	-3,9014	0,8449	0,0183	
taza de aprendizaje	0,1																
momentum	0,8																
Iteraciones	500	-0,6326	-48,6683	-9,5490	-38,8907	-10,1998	-3,0182	-3,0183	-3,0181	-3,0181	-3,0182	-3,0182	-3,0184	-3,0183	0,8412	0,0054	
taza de aprendizaje	0,2																
momentum	0,8																
Iteraciones	500	-0,5385	-59,2503	-6,3767	-52,2641	-16,3180	-3,1612	-3,1613	-3,1612	-3,1612	-3,1612	-3,1613	-3,1613	-3,1613	0,8407	0,0069	
taza de aprendizaje	0,3																
momentum	0,8																
Iteraciones	500	-0,4298	-67,2343	-22,3229	-57,3013	-23,6936	-3,3056	-3,3056	-3,3056	-3,3056	-3,3056	-3,3056	-3,3056	-3,3056	0,8411	0,0087	
taza de aprendizaje	0,4																
momentum	0,8																
Iteraciones	500	-0,2914	-74,6464	-24,0604	-52,5184	-33,7243	-3,4724	-3,4724	-3,4724	-3,4724	-3,4724	-3,4724	-3,4724	-3,4724	0,8429	0,0108	



taza de aprendizaje	0,5															
momentum	0,8															
Iteraciones	500	-0,1455	-77,7253	-7,2874	-60,6998	-21,7772	-3,6594	-3,6594	-3,6594	-3,6594	-3,6594	-3,6594	-3,6594	-3,6594	0,8439	0,0133
taza de aprendizaje	0,6															
momentum	0,8															
Iteraciones	500	-0,0243	-80,3844	-11,6994	-57,1143	-19,3041	-3,8438	-3,8438	-3,8438	-3,8438	-3,8438	-3,8438	-3,8438	-3,8438	0,8445	0,0164
taza de aprendizaje	0,7															
momentum	0,8															
Iteraciones	500	0,0922	-80,4097	-7,0667	-16,1863	-45,6130	-4,0387	-8,0774	-4,0387	-4,0387	-4,0387	-4,0387	-4,0387	-4,0387	0,8446	0,0201
taza de aprendizaje	0,8															
momentum	0,8															
Iteraciones	500	0,2119	-64,3591	-9,4552	-7,2967	-53,4124	-4,2615	-4,2614	-4,2614	-4,2614	-4,2614	-4,2614	-4,2614	-4,2614	0,8435	0,0247
taza de aprendizaje	0,9															
momentum	0,8															
Iteraciones	500	0,4956	-7,2041	-8,3451	-8,2389	-8,3482	-4,9307	-4,9307	-4,9307	-4,9307	-4,9307	-4,9307	-4,9307	-4,9307	0,8038	0,0319
taza de aprendizaje	0,1															
momentum	0,9															
Iteraciones	500	-0,5164	-58,1792	-15,3360	-52,9238	-10,1912	-3,1843	-3,1843	-3,1843	-3,1843	-3,1843	-3,1843	-3,1843	-3,1843	0,8405	0,0068
taza de aprendizaje	0,2															
momentum	0,9															
Iteraciones	500	-0,3054	-77,0015	-10,8562	-53,0560	-30,4435	-3,4703	-3,4703	-3,4703	-3,4703	-3,4703	-3,4702	-3,4703	-3,4703	0,8430	0,0103



taza de aprendizaje	0,3															
momentum	0,9															
Iteraciones	500	0,9995	8,8162	7,7526	5,8424	11,5958	-41,224	-11,774	-14,503	-12,358	-18,533	-19,983	-8,0491	-15,014	0,0116	0,0382
taza de aprendizaje	0,4															
momentum	0,9															
Iteraciones	500	0,1607	-55,8576	-7,3266	-55,2819	-39,8718	-4,1484	-4,1484	-4,1484	-4,1484	-4,1484	-4,1484	-4,1484	-4,1484	0,8448	0,0217
taza de aprendizaje	0,5															
momentum	0,9															
Iteraciones	500	0,7771	-6,2555	-6,0373	-5,6545	-6,2803	-3,8491	-20,026	-15,831	-25,734	-3,8490	-15,595	-24,866	-24,223	0,8037	0,0483
taza de aprendizaje	0,6															
momentum	0,9															
Iteraciones	500	0,9975	-5,5067	-4,2103	-4,5083	-4,1822	-18,178	-18,153	-39,068	-45,700	-18,216	-18,266	-18,758	-21,123	0,8034	0,0666
taza de aprendizaje	0,7															
momentum	0,9															
Iteraciones	500	1,0036	-8,5457	-8,7923	-7,2907	-8,6641	-11,206	-11,210	-11,212	-11,206	-11,210	-11,208	-41,060	-11,216	0,8037	0,0606
taza de aprendizaje	0,8															
momentum	0,9															
Iteraciones	500	1,0053	-10,4109	165,0037	147,824	162,1458	-28,012	-37,395	-27,129	-21,879	-60,790	-26,203	-32,755	-18,602	0,8037	0,0886
taza de aprendizaje	0,9															
momentum	0,9															
Iteraciones	500	1,0022	-6,1969	-6,3010	-6,2526	-6,2897	-16,041	-16,041	-16,040	-16,041	-16,041	-16,041	-16,041	-16,040	0,8037	0,0769

Tabla 5 Datos obtenidos en el experimento con dos capas y 12 neuronas



PARAMETROS	UMBRAL NODOS																								COEF COR	ERROR ACUM		
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23			24	
Taza de aprendizaje	0,1																											
Momentum	0,2																											
Iteraciones	500	-0,68	-4,92	-4,73	-9,55	-28,49	-6,98	-6,81	-8,56	-12,0	-6,82	-5,82	-7,01	-8,99	-3,04	-3	-3,0	-3,0	-3,0	-3,0	-3,04	-3,04	-3,04	-3,04	-3,04	0,85	0,00	
Taza de aprendizaje	0,2																											
Momentum	0,2																											
Iteraciones	500	-0,67	-3,79	-6,67	-12,3	-38,93	-8,76	-8,08	-10,2	-12,8	-8,31	-6,85	-8,57	-10,4	-3,41	-3,4	-3,4	-3,4	-3,4	-3,4	-3,41	-3,41	-3,41	-3,4	-3,41	-3,41	0,85	0,00
Taza de aprendizaje	0,3																											
Momentum	0,2																											
Iteraciones	500	-0,66	-5,12	-30,46	-6,79	-39,94	-8,99	-8,30	-9,05	-10,8	-8,36	-7,88	-8,90	-10,5	-3,57	-3,5	-3,5	-3,5	-3,5	-3,5	-3,57	-3,57	-3,57	-3,5	-3,57	-3,57	0,84	0,01
Taza de aprendizaje	0,4																											
Momentum	0,2																											
Iteraciones	500	-0,65	-6,20	-38,32	-7,67	-42,61	-9,70	-9,29	-9,67	-11,0	-9,31	-7,89	-9,65	-10,8	-3,69	-3,6	-3,6	-3,6	-3,6	-3,6	-3,69	-3,69	-3,69	-3,6	-3,69	-3,69	0,84	0,01
Taza de aprendizaje	0,5																											
Momentum	0,2																											
Iteraciones	500	-0,65	-16,44	-40,75	-8,63	-43,05	-10,7	-9,98	-10,3	-12,2	-10,3	-7,70	-10,3	-12,1	-3,76	-3,7	-3,7	-3,7	-3,7	-3,7	-3,76	-3,76	-3,76	-3,7	-3,76	-3,76		0,01
Taza de aprendizaje	0,6																											
Momentum	0,2																											
Iteraciones	500	-0,63	-26,69	-31,62	-9,25	-39,60	-13,4	-12	-12,5	-16,5	-12,6	-8,8	-12,8	-16,5	-3,82	-3,8	-3,8	-3,8	-3,8	-3,8	-3,82	-3,82	-3,82	-3,8	-3,82	-3,82	0,84	0,01
Taza de aprendizaje	0,7																											
Momentum	0,2																											
Iteraciones	500	-0,60	-43,63	-51,90	-6,53	-14,41	-12,3	-11,8	-12,0	-12,9	-12,1	-10,1	-12,0	-12,7	-3,86	-3,8	-3,8	-3,8	-3,8	-3,8	-3,86	-3,86	-3,86	-3,8	-3,86	-3,86	0,84	0,01



Anexo 3

=== Run information ===

Scheme: weka.classifiers.functions.MultilayerPerceptron -L 0.1 -M 0.2 -N 500 -V 0 -S 0
-E 20 -H "4, 8, 12" -G -R

Relation: R_data_frame-weka.filters.unsupervised.attribute.Remove-R1-2

Instances: 755259

Attributes: 8

insumos_set1.1

insumos_set1.2

insumos_set1.3

insumos_set1.4

insumos_set1.5

insumos_set1.6

insumos_set1.7

insumos_set1.8

Test mode: evaluate on training data

=== Classifier model (full training set) ===

Linear Node 0

Inputs	Weights
--------	---------

Threshold	0.8535443671196759
-----------	--------------------

Node 13	-3.8538639705184075
---------	---------------------

Node 14	-3.8475088316868913
---------	---------------------



Node 15	-3.6428899580917897
Node 16	-3.867067424865637
Node 17	-3.7902030432125944
Node 18	-3.684604483113905
Node 19	-3.952806269019952
Node 20	-3.8699092776509834
Node 21	-3.808109444614606
Node 22	-3.7029868408628497
Node 23	-3.87875169017289
Node 24	-3.8764368777731315

Sigmoid Node 1

Inputs	Weights
Threshold	-3.9166893361199415
Attrib insumos_set1.1	0.270235612139781
Attrib insumos_set1.3	-0.06252935049712982
Attrib insumos_set1.4	8.760596570741368
Attrib insumos_set1.5	1.1415949442162998
Attrib insumos_set1.6	-1.099945333601301
Attrib insumos_set1.7	0.12705552922500207
Attrib insumos_set1.8	0.3664977876356169

Sigmoid Node 2

Inputs	Weights
Threshold	-4.278325103057062
Attrib insumos_set1.1	1.057654054609162
Attrib insumos_set1.3	0.1323381031074487
Attrib insumos_set1.4	14.145225771965062



Attrib insumos_set1.5	6.609085764515174
Attrib insumos_set1.6	-0.019455236864447226
Attrib insumos_set1.7	-10.177489603579037
Attrib insumos_set1.8	-1.894658796952856

Sigmoid Node 3

Inputs	Weights
Threshold	9.558156776093039
Attrib insumos_set1.1	0.377751905182555
Attrib insumos_set1.3	-0.2913660802581893
Attrib insumos_set1.4	-12.257094351922571
Attrib insumos_set1.5	35.55020871975956
Attrib insumos_set1.6	-21.695540114024425
Attrib insumos_set1.7	-24.692608056247195
Attrib insumos_set1.8	1.1938691055218846

Sigmoid Node 4

Inputs	Weights
Threshold	2.5120602704948385
Attrib insumos_set1.1	-0.0922666647571561
Attrib insumos_set1.3	0.013306419985911516
Attrib insumos_set1.4	5.508629931011525
Attrib insumos_set1.5	1.1143871893115882
Attrib insumos_set1.6	0.12119373490718122
Attrib insumos_set1.7	-1.409104440245719
Attrib insumos_set1.8	-0.4250084230552745



Sigmoid Node 5

Inputs	Weights
Threshold	-11.400386421455677
Node 1	2.693168387799983
Node 2	-0.6541968799542777
Node 3	5.15149989067618
Node 4	3.8602613118171423

Sigmoid Node 6

Inputs	Weights
Threshold	-9.285617266882658
Node 1	1.4830650846296416
Node 2	3.2839007910443887
Node 3	2.023020201397878
Node 4	2.2966016241636074

Sigmoid Node 7

Inputs	Weights
Threshold	-13.882844434453672
Node 1	5.065670685126011
Node 2	2.209449101308236
Node 3	6.52978670624855
Node 4	6.367480281410414

Sigmoid Node 8

Inputs	Weights
Threshold	-7.716200779505752
Node 1	-16.72514573238476
Node 2	16.839546435722497



Node 3 6.929243899496752

Node 4 3.332492360568442

Sigmoid Node 9

Inputs Weights

Threshold -10.632461411712242

Node 1 2.433410784295617

Node 2 0.36822895264766997

Node 3 4.284410732926187

Node 4 3.022432558041467

Sigmoid Node 10

Inputs Weights

Threshold 0.2940774454183815

Node 1 2.9464794989025744

Node 2 -14.327122425502814

Node 3 -17.277212752725294

Node 4 7.5275452818876

Sigmoid Node 11

Inputs Weights

Threshold -16.39808274683178

Node 1 5.546956578603528

Node 2 0.1274831368733109

Node 3 7.828376999050327

Node 4 7.230364278461373



Sigmoid Node 12

Inputs	Weights
Threshold	-16.226326940956483
Node 1	14.063845744036097
Node 2	-0.40941876597300975
Node 3	6.022222922782451
Node 4	-2.8436402869065445

Sigmoid Node 13

Inputs	Weights
Threshold	-2.8724315927446473
Node 5	-0.9357863491111286
Node 6	-0.4429007972018434
Node 7	-0.06493970874581231
Node 8	-1.1817352529418
Node 9	-0.7781119291216564
Node 10	-0.42001642932401223
Node 11	-0.560031238247444
Node 12	-3.506752564305925

Sigmoid Node 14

Inputs	Weights
Threshold	-2.9078428476453992
Node 5	-0.9589451073055408
Node 6	-0.5090042138533861
Node 7	-0.13877075199792163
Node 8	-1.0714667928010595
Node 9	-0.7645208014160131



Node 10	-0.3930238368408911
Node 11	-0.5392738139681803
Node 12	-3.4994771674213934

Sigmoid Node 15

Inputs	Weights
Threshold	-3.7764986359930783
Node 5	-1.1560773250521137
Node 6	-1.187403050600709
Node 7	-1.1523238227156902
Node 8	0.8763798779558664
Node 9	-1.0705184202786548
Node 10	0.25139407045426576
Node 11	-1.3054741775387733
Node 12	-2.7434286780391197

Sigmoid Node 16

Inputs	Weights
Threshold	-2.824697936789963
Node 5	-0.8987186413524257
Node 6	-0.4329680666548803
Node 7	-0.06696736064859485
Node 8	-1.3208488803061236
Node 9	-0.7446145489874474
Node 10	-0.4521320485621176
Node 11	-0.384162644047338
Node 12	-3.593498835586834



Sigmoid Node 17

Inputs	Weights
Threshold	-3.142567981511349
Node 5	-0.9964277603524652
Node 6	-0.6256069118197656
Node 7	-0.30251584942479126
Node 8	-0.5009828227141849
Node 9	-0.8610616674122606
Node 10	-0.21508742658672134
Node 11	-0.8837382577940159
Node 12	-3.3093569833458587

Sigmoid Node 18

Inputs	Weights
Threshold	-3.602023758981082
Node 5	-1.143380741964326
Node 6	-1.0799646299069308
Node 7	-0.8349976922901674
Node 8	0.5082267484182674
Node 9	-0.9656528157554245
Node 10	0.12487531437310227
Node 11	-1.2701113170271192
Node 12	-2.8879050085684983

Sigmoid Node 19

Inputs	Weights
Threshold	-2.465754592174881
Node 5	-0.8483531414555344



Node 6	-0.395623175054262
Node 7	-0.08884809462016506
Node 8	-2.2401146291801624
Node 9	-0.7584726993841276
Node 10	-0.7516073595015745
Node 11	-0.008830959549930687
Node 12	-3.6277623784137347

Sigmoid Node 20

Inputs	Weights
Threshold	-2.8058279419748047
Node 5	-0.967250693489379
Node 6	-0.40046427188558137
Node 7	-0.0063847605260289675
Node 8	-1.3714963417568249
Node 9	-0.8202358851671747
Node 10	-0.471284188779729
Node 11	-0.4620717288175451
Node 12	-3.546074245011956

Sigmoid Node 21

Inputs	Weights
Threshold	-3.0729894662250112
Node 5	-0.958358285870022
Node 6	-0.5031937768951014
Node 7	-0.18103812936278652
Node 8	-0.721798131025911
Node 9	-0.790279202294223



Node 10 -0.2555997960671451
Node 11 -0.7440572916008726
Node 12 -3.4565883015156613

Sigmoid Node 22

Inputs	Weights
Threshold	-3.527235259132694
Node 5	-1.0890492724806768
Node 6	-0.9354079422019285
Node 7	-0.6522718426537485
Node 8	0.3151764660095959
Node 9	-0.9218650434611024
Node 10	0.08145579368482012
Node 11	-1.2330755902998853
Node 12	-3.016720400498222

Sigmoid Node 23

Inputs	Weights
Threshold	-2.775179960550313
Node 5	-0.8909909943123739
Node 6	-0.4513684644085465
Node 7	-0.09109733716624845
Node 8	-1.3999287334966692
Node 9	-0.7768879174379987
Node 10	-0.4990899936756317
Node 11	-0.37091645435603127
Node 12	-3.5567531749879677



Sigmoid Node 24

Inputs	Weights
Threshold	-2.689242845220298
Node 5	-0.6764028047835126
Node 6	-0.1759199595503442
Node 7	0.40343798962023786
Node 8	-2.3591217240948796
Node 9	-0.6608313027404636
Node 10	-0.49967495021054786
Node 11	0.36757121875481724
Node 12	-4.115362852898514

Class

Input
Node 0

Time taken to build model: 23919.58 seconds

=== Evaluation on training set ===

Time taken to test model on training data: 10.29 seconds

=== Summary ===

Correlation coefficient	0.9823
Mean absolute error	34.4363
Root mean squared error	66.6036
Relative absolute error	12.0457 %
Root relative squared error	18.9307 %
Total Number of Instances	755259