



ESCUELA POLITÉCNICA DEL EJÉRCITO

CARRERA DE INGENIERÍA GEOGRÁFICA Y
DEL MEDIO AMBIENTE

PROYECTO DE GRADO PARA LA OBTENCIÓN DEL TÍTULO
DE INGENIERÍA

TRANSFORMACIÓN DE COORDENADAS PLANAS ENTRE LOS
SISTEMAS GEODÉSICOS PSAD56 Y SIRGAS MEDIANTE UNA
RED NEURONAL ARTIFICIAL

REALIZADO POR:

ROMERO CHASIPANTA RICARDO VINICIO

SANGOLQUÍ – ECUADOR

FEBRERO - 2013

CERTIFICACIÓN

Certificamos que el presente proyecto de grado fue realizado en su totalidad por el Sr. Romero Chasipanta Ricardo Vinicio y cumple con los requisitos teóricos, técnicos, metodológicos, científicos y legales establecidos por la ESPE como documento previo a la obtención del título de Ingeniero Geógrafo y del Medio Ambiente.

Sangolquí, 06 de febrero de 2013.

Dr. Alfonso Tierra PhD
DIRECTOR

Ing. Marco Luna MSc
CODIRECTOR

RESUMEN

El presente documento presenta la aplicación de la metodología de redes neuronales artificiales en la transformación de coordenadas planas (Este, Norte) desde un sistema geodésico local a un sistema global que sea compatible con escalas catastrales mayores a 1: 5000, aplicado a un sector del Distrito Metropolitano de Quito. Debido a que el Ecuador cuenta con parámetros de transformación oficiales compatibles con escalas menores a 1:25000, es necesario desarrollar otra metodología que permita mejorar los niveles de precisión.

El tipo de red neuronal artificial que se utilizó fue una red unidireccional, multicapa con el algoritmo de retropropagación y el método de optimización Levenberg – Marquardt. Los resultados que se obtuvieron con la red neuronal fueron comparados con un cálculo similar realizado con parámetros de transformación usando los mismos datos, teniendo como resultado que la mejor opción es utilizar la metodología de redes neuronales artificiales para transformar coordenadas con precisiones compatibles hasta escalas menores a 1: 2500

ABSTRACT

This document presents the application of the Artificial Neural Networks methodology to transform projected coordinates (east, north) from a local geodesic system to a global system like SIRGAS that is compatible with cadastral scales greater than 1: 5000; it was executed within Metropolitan District of Quito. Due to Ecuador has official transformation parameters which are compatible with scales lesser than 1:25000, is necessary to develop other methodology whose allow to improve the precision.

The type of artificial neural network used was a multilayer feed forward network with retro propagation algorithm and the optimization of Levenberg – Marquardt. The outcomes obtained in this document were compared between with a similar compute made up with transformation parameters, using the same dates. In conclusion the best option was the methodology of artificial neural network, transforming coordinates within the precision to scales lesser than 1:25000.

DEDICATORIA

Este proyecto está dedicado a:

Mi familia que ha sido un ejemplo de unidad y esfuerzo,
los mismos que me han ayudado a cumplir mis metas y desafíos
en especial a mis padres que a pesar de todo siempre me han apoyado en momentos de
decisión que han sido cruciales en mi vida.

Mis mejores amigos que en cada encuentro han afianzado mis ideales y principios
permitiendo ser más humano y mejor profesional.

AGRADECIMIENTOS

A Dios por ser el pilar de mi voluntad y dueño de mis actos.

A mi familia por enseñarme los valores y principios de los que me siento orgulloso.

A mis profesores que impartieron además de su cátedra, lecciones de vida y de trabajo.

A mis compañeros Andrea Viteri y Christian Pilapanta que juntos logramos hacer un grupo no solo de profesionales que buscan superarse día a día sino de amigos.

A Yoly que siempre me demostró su apoyo en confianza en mi.

A mi director y codirector de tesis por ser guías en el cumplimiento de los objetivos de este proyecto y por incentivar la investigación desde temprana edad.

PRÓLOGO

Es de gran importancia mantener un sistema único de referencia de coordenadas, a fin de que la cartografía que represente los detalles mínimos del terreno sean fácilmente georreferenciados en campo y de esta manera el usuario pueda integrar nueva información cartográfica a la existente. El problema se presenta cuando se cuenta con diferentes sistemas de coordenadas y más aún si entre estos sistemas se presentan locales y globales que necesariamente necesitan ser transformados para empatar la información.

En este marco se encuentra la presente investigación que contiene una metodología nueva como es el caso de redes neuronales artificiales aplicado a resolver este problema estrictamente geodésico, la cual será la base para determinar si logra mejor las precisiones en el cálculo de las coordenadas con la finalidad que sea capaz de ser utilizado en la cartografía catastral, la misma que es el insumo principal en la planificación para el desarrollo de un territorio.

Además se puede evaluar esta metodología con respecto a las técnicas anteriormente empleadas como es el caso de parámetros de transformación calculados con mínimos cuadrados, esto permitirá tener una idea que la calidad y validez de ambos métodos para que el lector tenga la capacidad de discernir su decisión por cual metodología optar para resolver este complejo problema.

ÍNDICE DE CONTENIDO.

	Pág.
CAPÍTULO 1. ASPECTOS GENERALES.	
1.1. INTRODUCCIÓN	1
1.2. ANTECEDENTES	2
1.3. DESCRIPCIÓN DEL PROBLEMA	3
1.4. JUSTIFICACIÓN	4
1.5. DESCRIPCIÓN DEL ÁREA DE ESTUDIO	5
1.6. OBJETIVO GENERAL	5
1.7. OBJETIVOS ESPECÍFICOS	5
1.8. METAS	6
CAPÍTULO 2. MARCO TEÓRICO	
2.1. SISTEMAS DE REFERENCIA TOPOCÉNTRICOS	7
2.1.1. PROVISIONAL SOUTH AMERICA DATUM	7
2.2. SISTEMAS DE REFERENCIA GEOCÉNTRICOS	8
2.2.1. SISTEMA DE REFERENCIA GEOCÉNTRICO PARA LAS AMÉRICAS	8
2.3. SISTEMAS DE PROYECCIÓN CARTOGRÁFICA	9
2.3.1. SISTEMA UNIVERSAL TRANSVERSA DE MERCATOR (UTM)	10
2.3.2. TRANSVERSA MERCATOR DE QUITO (TMQ)	11
2.4. TRANSFORMACIONES ENTRE SISTEMAS DE REFERENCIA GEODÉSICOS	11
2.4.1. TRANSFORMACIÓN TRIDIMENSIONAL. MÉTODO DE HELMERT	12
2.4.2. TRANSFORMACIÓN BIDIMENSIONAL CONFORME	14
2.5. AJUSTE DE MÍNIMOS CUADRADOS	16

2.6. REDES NEURONALES ARTIFICIALES	18
2.6.1. NEURONA BIOLÓGICA	19
2.6.2. FUNDAMENTOS BIOLÓGICOS	19
2.6.3. SEMEJANZAS ENTRE NEURONAS BIOLÓGICAS Y NEURONAS ARTIFICIALES	20
2.6.4. ELEMENTOS BÁSICOS DE UNA RED NEURONAL ARTIFICIAL	21
2.6.5. PROCESOS DE APRENDIZAJE DE UNA RNA	23
2.6.6. TIPOS DE APRENDIZAJE	25
2.6.7. FUNCIONES DE ACTIVACIÓN O DE TRANSFERENCIA	26
2.6.8. ARQUITECTURA DE REDES NEURONALES ARTIFICIALES	26
2.7. REDES NEURONALES ARTIFICIALES MULTICAPA (RNAM)	28
2.7.1. ALGORITMO DE RETROPROPAGACIÓN (APRENDIZAJE VISTO COMO GRADIENTE DESCENDIENTE)	30
2.7.2. MÉTODO DE OPTIMIZACIÓN DE LEVENBERG – MARQUARDT	36
2.8. ENTRENAMIENTO DE UNA RED NEURONAL ARTIFICIAL MULTICAPA	37
CAPÍTULO 3. METODOLOGÍA	
3.1. AJUSTE CON EL MÉTODO DE MÍNIMOS CUADRADOS	41
3.2. SELECCIÓN DE PUNTOS PARA EL ENTRENAMIENTO DE LA RED NEURONAL ARTIFICIAL	43
3.3. PRE-PROCESAMIENTO Y POST-PROCESAMIENTO ESTADÍSTICO DE LOS DATOS	44
3.4. SELECCIÓN DE LA ARQUITECTURA DE LA RNA	45
3.5. ENTRENAMIENTO DE LA RED NEURONAL ARTIFICIAL	46
3.6. MAPA DE DISTORSIONES	50
CAPÍTULO 4. DISCUSIÓN DE LOS RESULTADOS	
4.1. ANÁLISIS DE LOS RESULTADOS OBTENIDOS CON EL AJUSTE DE MÍNIMOS CUADRADOS	51

4.2. ANÁLISIS DE LOS RESULTADOS OBTENIDOS CON UNA RED NEURONAL ARTIFICIAL	53
--	-----------

4.3. COMPARACIÓN ENTRE LOS RESULTADOS OBTENIDOS CON PARÁMETROS DE TRANSFORMACIÓN Y UNA R.N.A.M.	59
--	-----------

CAPÍTULO 5. CONCLUSIONES Y RECOMENDACIONES

5.1. CONCLUSIONES	61
--------------------------	-----------

5.2. RECOMENDACIONES	62
-----------------------------	-----------

ANEXOS

ANEXO 1. EJERCICIO DE INICIACIÓN DE REDES NEURONALES ARTIFICIALES.

ANEXO 2. COORDENADAS DE LOS PUNTOS QUE SERÁN PRESENTADOS A LA RNA PARA EL ENTRENAMIENTO, DIVIDIDOS EN DATOS DE ENTRENAMIENTO, VALIDACIÓN Y COMPROBACIÓN.

ANEXO 3. PROGRAMA DISEÑADO EN MATLAB CAPAZ DE TRANSFORMAR COORDENADAS PLANAS DESDE UN SISTEMA LOCAL A UNO GLOBAL.

ANEXO 4. MAPA DE DISTORSIONES

ANEXO 5. RESULTADOS DE LA TRANSFORMACIÓN BIDIMENSIONAL USANDO PARÁMETROS DE TRANSFORMACIÓN.

ANEXO 6. RESULTADOS DE LA TRANSFORMACIÓN DE COORDENADAS CON UNA RED NEURONAL ARTIFICIAL MULTICAPA.

REFERENCIAS BIBLIOGRÁFICAS

ÍNDICE DE TABLAS.

Tabla. 1.1. Coordenadas del área de estudio.

Tabla. 2.1. Clasificación de los sistemas de proyección cartográfica.

Tabla. 2.2. Parámetros proyección TMQ.

Tabla. 3.1. Coordenadas de los puntos utilizados para calcular los parámetros de transformación por el método de mínimos cuadrados.

Tabla. 3.2. Valores de los parámetros para detener el entrenamiento de la RNA.

Tabla. 4.1. Parámetros de transformación calculados con mínimos cuadrados.

Tabla. 4.2. Resultados obtenidos en la transformación de coordenadas utilizando parámetros de transformación.

Tabla. 4.3. Resultados obtenidos en la transformación de coordenadas utilizando una RNAM.

Tabla. 4.4. Cuadro resumen de los resultados obtenidos con Parámetros de Transformación y una Red Neuronal Artificial.

ÍNDICE DE FIGURAS.

Figura. 2.1. Diferencia entre un sistema topocéntrico y geocéntrico

Figura. 2.2. Transformación de Helmert

Figura. 2.3. Transformación bidimensional de Helmert

Figura. 2.4. Proceso de sinapsis de una neurona biológica

Figura. 2.5. Semejanza entre una neurona biológica y una neurona artificial

Figura. 2.6. Modelo de una neurona artificial

Figura. 2.7. Generalización por Aprendizaje (a), Sobreaprendizaje (b)

Figura. 2.8. Funciones de activación más empleadas

Figura. 2.9. Arquitecturas comunes de redes neuronales artificiales

Figura. 2.10. Funciones de transferencia más usadas en una red multicapa

Figura. 2.11. Funcionamiento lógico del algoritmo de retropropagación

Figura. 2.12. Cálculo de la señal de error de una red neuronal multicapa

Figura. 2.13. Paso de la función de error en una función sigmoideal

Figura. 2.14. Superficie de error en un mínimo local o global

Figura. 2.15. Evolución de las curvas de error para los 3 subconjuntos de datos que se presentan en el entrenamiento de la RNA.

Figura. 3.1. Puntos seleccionados para el ajuste de mínimos cuadrados observados tanto en la cartografía de PSAD56 como en SIRGAS00

Figura. 3.2. Distribución de los puntos seleccionados para el entrenamiento y aprendizaje de la RNA

Figura. 3.3. Topología de la RNA usada en el presente trabajo

Figura. 3.4. Proceso para desarrollar la metodología del entrenamiento de la RNA en la transformación de coordenadas

Figura. 4.1. Determinación de zonas con eventos extremos de distorsión en la zona de estudio utilizando el ajuste con mínimos cuadrados

Figura. 4.2. Distorsiones generadas en la posición de los 60 datos utilizando parámetros de transformación

Figura. 4.3. Ajuste de los datos de las coordenadas en la simulación de la RNAM

Figura. 4.4. Ajuste de los datos de las coordenadas después del entrenamiento de la RNAM

Figura. 4.5. Diferencia (m) de los valores en coordenadas Este para los 60 puntos observados

Figura. 4.6. Diferencia (m) de los valores en coordenadas Norte para los 60 puntos observados

Figura. 4.7. Diferencias (m) de la posición de los 60 datos en estudio

GLOSARIO

- **ALTURA ELIPSOIDAL:** altura medida desde el punto sobre la superficie terrestre hasta la superficie elipsoidal formando una normal con esta última.
- **ALTURA ORTOMÉTRICA:** altura que se mide desde un punto sobre la superficie terrestres siguiendo la línea de la plomada hasta la superficie del geoide. Esta altura no representa una línea recta debido a las fuerzas de gravedad y centrífuga de la Tierra que actúan sobre ella.
- **APRENDIZAJE:** etapa de la red en donde ha aprendido a generalizar los patrones de los datos de entrada, siendo capaz de otorgar respuestas con rendimientos similares a pesar de cambiar los datos de entrada.
- **COOTAD:** Código Orgánico de Ordenamiento Territorial, Autonomía y Descentralización.
- **DATUM:** origen de coordenadas de sistemas topocéntricos, que es determinado por sus coordenadas referidas a un elipsoide de referencia, además del desvío de la vertical en el punto.
- **DISTORSIONES:** discrepancias, diferencias, variaciones entre la magnitud, dirección y sentido del resultado deseado y el resultado calculado.
- **ELIPSOIDE DE REFERENCIA:** figura ideal o matemática de la Tierra conformada por parámetros observados sobre la superficie o el exterior.
- **ENTRENAMIENTO:** proceso iterativo de aprendizaje de una red neuronal artificial, en el cual se busca obtener un rendimiento eficiente de la red, en términos de tiempo, error y predicción.
- **EXTRAPOLACIÓN:** predicción de valores que se suponen tendrán un comportamiento similar al de un fenómeno en particular que sigue sus propias reglas, el cual se encuentra fuera del límite de espacio o tiempo.
- **FUNCIÓN DE ACTIVACIÓN:** función matemática continua, creciente y monótona que se encarga de activar o desactivar la señal que será enviada a las neuronas posteriores.
- **GENERALIZACIÓN:** capacidad de las redes neuronales artificiales de predecir patrones extremos que se pueden presentar en los datos.
- **GEOIDE:** superficie compleja que se asemeja a la superficie del nivel medio de los mares en calma, en función de del modelo geopotencial.

- **GRADIENTE DESCENDIENTE:** gradiente opuesto a la función de error de la red, el cual se encarga de seguir el mismo sentido y dirección del vector error con la finalidad de encontrar el mínimo error posible.
- **GRS80:** Geodetic Reference System 1980.
- **ITRF:** International Terrestrial Reference Frame.
- **ITRS:** International Terrestrial Reference System.
- **MARCO GEODÉSICO:** Materialización del sistema geodésico en puntos con coordenadas de precisión y exactitud, realizadas en campañas de mediación.
- **NIMA:** National Imagery Mapping Agency.
- **ONDULACIÓN GEOIDAL:** diferencia de altura existente entre la superficie elipsoidal y el geoide.
- **PARÁMETROS DE TRANSFORMACIÓN:** variables calculadas que se utilizan para compatibilizar dos sistemas de referencia de coordenadas que son diferentes en posición, orientación o tamaño.
- **PESOS SINÁPTICOS:** valores numéricos que determinan el potencial de las señales provenientes de las neuronas de entrada y ocultas.
- **PRECISIÓN:** proximidad de las mediciones entre sí, con respecto a un valor de referencia.
- **PSAD56:** Provisional South America Datum 1956.
- **RETROPROPAGACIÓN, ALGORITMO DE:** algoritmo de aprendizaje muy común en redes neuronales artificiales multicapa, el cual calcula el error de la red actualizando los pesos sinápticos hasta que estos se ajusten de tal manera que brinden una respuesta cercana a la deseada.
- **SIRGAS:** Sistema de Referencia Geocéntrico para las Américas.
- **SOBREAPRENDIZAJE:** etapa en que la red neuronal artificial memoriza los patrones de entrada y pierde la capacidad de generalizar ante otros eventos externos, tal es así que al presentar diferentes conjuntos de entrada, las respuestas serán similares.
- **TEST:** comprobación del aprendizaje de la red neuronal artificial, que por lo general se presenta a la red un conjunto de datos que siguen una distribución aleatoria para determinar si el entrenamiento ha sido eficiente.
- **TMQ:** Transversa de Mercator Quito, es una proyección cartográfica que se aplica solamente en el Distrito Metropolitano de Quito, la misma que es una modificación de la UTM.

- **UMBRAL:** límite inferior y/o superior que determina la amplitud de la señal antes de ingresar a la función de activación.
- **UTM:** Universal Transversa de Mercator, proyección cartográfica.
- **VEMOS:** Modelo de Velocidades para Suramérica y el Caribe.
- **WGS84:** World Geodetic System 1984.

CAPÍTULO 1

ASPECTOS GENERALES

1.1. INTRODUCCIÓN

Entre las primeras interrogantes de la humanidad desde ya varias épocas es conocer con certeza ¿dónde estamos?, esta duda ha hecho que varios pensadores propongan varias teorías sobre la figura de la Tierra y leyes que la gobiernan. Aunque en la actualidad se conoce la verdadera forma del planeta y se siguen planteando teorías y leyes que demuestran los fenómenos naturales que rigen la dinámica de la Tierra, aún se discute la misma pregunta para conocer con exactitud nuestra ubicación sobre la superficie.

En el transcurso de la historia muchos investigadores e interesados se dedicaron a responder esta interrogante con la adopción de sistemas de coordenadas referidas a elipsoides de revolución que representaban la forma matemática de la Tierra y con su origen de coordenadas materializado sobre la superficie, lo cual dio la oportunidad de representar en planos, cartas o mapas los detalles de la corteza terrestre, pero esta metodología de posicionamiento es considerada local o regional, es decir, cada país adoptaba un sistema de referencia propio que se acople mejor a sus condiciones geográficas.

Actualmente, con el desarrollo de la tecnología de posicionamiento satelital se puede obtener la posición de un punto en la Tierra con cierto nivel de confianza, referenciada a un sistema de coordenadas global, con lo cual se pueden desarrollar trabajos, proyectos, investigaciones georreferenciadas a un sistema de coordenadas único. En este punto fue preciso determinar metodologías que permitan migrar las coordenadas de los sistemas de referencia clásicos a los actuales, manteniendo los niveles de precisión acorde a las necesidades y especificaciones técnicas de la cartografía de cada país.

1.2. ANTECEDENTES

La transformación de coordenadas de puntos que se encuentran en diferentes sistemas geodésicos se lo realiza a partir del surgimiento de los nuevos métodos de posicionamiento satelital, por lo que es importante que se defina y se estandarice un sistema único de referencia para la cartografía, es así que a partir de la utilización del sistema WGS84 (World Geodetic System 1984), en Ecuador se hizo necesario transformar la antigua cartografía que se encontraba referenciada en PSAD56 (Provisional South American Datum). Por tal motivo la NIMA (National Imagery and Mapping Agency) consideró para esta transformación 11 puntos de control en el Ecuador continental para calcular parámetros de transformación que consistieron en 3 traslaciones, dando errores de metros en algunas zonas del país, por lo que solamente era compatible para escalas pequeñas.

Además es importante conocer que el Ecuador cuenta con parámetros de transformación oficiales entre los sistemas PSAD56 y WGS84 los cuales son compatibles con escalas menores a 1: 25 000¹, estos parámetros de transformación aplica 3 traslaciones, 3 rotaciones y 1 diferencial de escala, por lo cual indican que son aplicables a sistemas de coordenadas cartesianas, es decir coordenadas (X, Y, Z) de un punto, si bien es cierto representa una ayuda para transformar la cartografía nacional, estos parámetros no son aplicables a escalas de mayor detalle. Posteriormente, se realizó investigaciones en este tema empleando el modelo de velocidades de placas tectónicas VEMOS (Velocity Model for SIRGAS) mejorando las precisiones de la transformación entre estos sistemas hasta escalas compatibles a 1: 15 000 y menores². Cabe recordar que estos resultados son aplicables solamente para coordenadas cartesianas y los puntos que se emplearon para el cálculo estaban distribuidos en todo el territorio continental.

Por otro lado, la determinación de parámetros de transformación empleando otras metodologías como las transformaciones bidimensionales con coordenadas planas (Este - Norte) resulta útil para obtener soluciones a este tema, en donde se calculan 4 parámetros

¹ Leiva, C., “ Determinación de parámetros de transformación entre los Sistemas PSAD56 y WGS84 para el país”, 2003

² Santacruz, A., “Transformación entre el sistema PSAD56 y los marcos de referencia ITRF utilizando modelos de Helmert y velocidades de placas tectónicas VEMOS”, 2010.

que consideran: 2 traslaciones, 1 rotación y 1 factor de escala. Se debe tener en cuenta que esta técnica puede generar errores sistemáticos, además que su entorno de validez es para áreas de extensión pequeña lo cual no permite una extrapolación de resultados, pero al no dar resultado ninguna otra técnica de transformación ya sea por la poca disponibilidad y calidad de los datos, se recurre a esta metodología³, que generalmente ha sido usado en áreas como la fotogrametría.

Siguiendo los lineamientos del párrafo anterior, se realizaron cálculos para determinar nuevos parámetros de transformación utilizando coordenadas planas proyectadas (Este - Norte) que sean compatibles con escalas de detalle catastral sea para zonas rurales así como también para zonas urbanas. El cálculo se realizó con la técnica de ajuste de mínimos cuadrados dando como resultado 4 parámetros de transformación que al calcular las coordenadas, éstas lograron ser compatibles con escalas menores a 1: 5 000, por lo tanto son aplicables solamente para zonas rurales⁴.

En el Ecuador la aplicación de redes neuronales artificiales en geodesia ha sido poco estudiada y desarrollada, a pesar de ello se demostró que al aplicar una red neuronal artificial utilizando coordenadas cartesianas (X, Y, Z) se puede transformar del sistema PSAD56 al SIRGAS (Sistema de Referencia Geocéntrico para las Américas) en escalas 1: 5000 y menores⁵. Pero esta metodología no se ha usado aplicando coordenadas planas.

1.3. DESCRIPCIÓN DEL PROBLEMA

En el país existen municipios o niveles de gobierno que cuentan con cartografía catastral referenciada en PSAD56 mientras que los proyectos actuales de posicionamiento satelital por GPS (Global Positioning System) están referenciados al datum geodésico WGS84, el cual es compatible con el ITRF2000 (International Terrestrial Reference Frame 2000), dado que no existen diferencias significativas desde el punto de vista cartográfico⁶. Por lo que los parámetros de transformación oficiales para Ecuador entre estos sistemas no se acoplan a estas escalas catastrales que necesitan los niveles de gobierno.

³ Pérez, R., "Parámetros de transformación entre el Sistema SIRGAS95 y los sistemas locales CDM y ROU-USAMS (Yacaré)", 2002.

⁴ Romero, R. & Tierra, A., "Parámetros de transformación entre sistemas de referencia proyectados UTM-PSAD56 Y SIRGAS00 para escalas catastrales", 2012.

⁵ Tierra, A., "Transformación entre los sistemas geodésicos PSAD56 y SIRGAS usando una Red Neuronal Artificial", 2009.

⁶ Tierra, A., "Estado actual del cambio para el Sistema de Referencia Geocéntrico SIRGAS95 en el Ecuador", 2007.

Por otro lado, la información que se necesita para transformar sistemas geodésicos de referencia y que además sean compatibles con escalas catastrales es muy limitada, por el hecho de que se necesita una cantidad necesaria de puntos de control de precisión en el territorio de estudio con coordenadas observadas en ambos sistemas. Esta limitante de información induce a usar en el cálculo la observación de puntos de las esquinas de los predios en lugar de puntos de control geodésicos.

Además cabe mencionar que a nivel mundial y regional con el desarrollo del posicionamiento satelital, va aumentando el número de usuarios de la tecnología GPS⁷ con nuevas aplicaciones como proyectos de infraestructura rural y urbana, delimitación de tierras, gestión del riesgo y ordenamiento territorial entre las más empleadas en planificación.

1.4. JUSTIFICACIÓN

Realizar nuevamente proyectos para el levantamiento del catastro de un municipio referenciado en SIRGAS para tener actualizada la base de información catastral implica una fuerte inversión económica, además de requerir el personal con la capacidad técnica indicada para realizar estos proyectos y, hardware y software entre el equipo tecnológico necesario.

Por otra parte, desde la publicación y vigencia del COOTAD (Código Orgánico de Ordenamiento Territorial, Autonomía y Descentralización), los niveles de gobierno descentralizados deben administrar y actualizar su sistema de información catastral, según el artículo 139 de este código, esto servirá para diseñar programas y proyectos dirigidos a un correcto ordenamiento territorial además de mitigar rezagos sociales del sector⁸, por lo tanto esto obliga a los municipios a cumplir con los requerimientos establecidos por la ley.

Por lo antes señalado es importante establecer una metodología que permita transformar la cartografía catastral de sistemas clásicos a modernos con los niveles de precisión

⁷Tierra, A., "Evaluación del EGM08 y EGM06 en el Ecuador a partir de datos GPS y nivelación geométrica", 2009.

⁸ González, G., "Cartografía catastral y planeación urbana y regional", Revista de Información y Análisis, num 18, México 2002.

requeridos, y además de ello que sea de forma eficiente para poder aprovechar las ventajas y oportunidades que ofrece la navegación satelital por GPS⁹.

1.5. DESCRIPCIÓN DEL ÁREA DE ESTUDIO

El área de estudio seleccionada comprende una extensión de aproximadamente 212 hectáreas que corresponden a 12 hojas catastrales escala 1:1000 con la siguiente referencia geográfica:

País: Ecuador

Provincia: Pichincha

Cantón: DM Quito

Las coordenadas locales en las cuales se encuentra el área de estudio están georreferenciadas en la proyección TMQ (Transversa Modificada para Quito), las mismas que están representadas en la tabla 1.1.

Tabla. 1.1. Coordenadas del área de estudio

TMQ – PSAD56		TMQ – SIRGAS00	
ESTE (m)	NORTE (m)	ESTE (m)	NORTE (m)
501500	9982000	501263.3	9981632.5
502700	9982000	502463.3	998163.5
502700	9982800	502463.3	9982432.5
501500	9982800	501263.3	9982432.5

1.6. OBJETIVO GENERAL

Determinar una metodología que permita transformar entre sistemas de referencia proyectados, utilizando una red neuronal artificial multicapa que facilite la migración de información optimizando recursos económicos y tiempo.

⁹ Tierra, A. et al, "Using an artificial neural network to improve the transformation of coordinates between classical geodetic reference frames", 2007

1.7. OBJETIVOS ESPECÍFICOS

- Observar coordenadas de puntos homólogos de las hojas catastrales en los sistemas TMQ-PSAD56 y TMQ-SIRGAS.
- Determinar la mejor arquitectura de la RNA mediante un entrenamiento supervisado y validación del aprendizaje.
- Transformar puntos de entrenamiento, validación y comprobación para determinar el error entre los valores transformados y observados a fin de conocer la capacidad de generalización y aprendizaje de la red.
- Comprobar los resultados obtenidos con la RNA con una transformación bidimensional conforme.

1.8. METAS

- Determinar tres conjuntos de datos: de entrenamiento, validación y comprobación de la RNA.
- Un programa diseñado en MATLAB que transforme las coordenadas planas de un sistema geodésicos clásico a uno geocéntrico.
- Mapa de distorsiones de las coordenadas Este – Norte calculadas vs las observadas.

CAPÍTULO 2

MARCO TEÓRICO

2.1. SISTEMAS DE REFERENCIA TOPOCÉNTRICOS

Los sistemas de referencia topocéntricos o locales son definidos por un elipsoide de referencia y un datum (origen) que mejor se acople a las condiciones geográficas de una región o país (dependiendo de la extensión), es decir, el punto origen se precisa en la superficie terrestre y a partir de este se materializan los vértices de una red geodésica utilizando métodos clásicos de triangulación. Es importante conocer que la definición del datum es el punto donde coincide la normal elipsoidal con la vertical del lugar, además estos sistemas solamente soportan el marco de referencia geodésico horizontal, lo que significa que únicamente se puede calcular coordenadas geodésicas (latitud, longitud) o proyectadas (Este-Norte), por consiguiente el sistema de referencia vertical es definido independientemente de las densificaciones de red por medio de campañas de nivelación desde una cota inicial, que generalmente se lo hace desde un mareógrafo.

La desventaja de estos sistemas locales es que cada país o región realiza la materialización de su red acorde con los parámetros del elipsoide y datum elegidos, lo cual provoca incompatibilidad entre otras redes adyacentes, especialmente en las zonas fronterizas.

2.1.1. PROVISIONAL SOUTH AMERICA DATUM 1956 (PSAD56)

Este sistema de referencia topocéntrico fue adoptado como sistema oficial por varios países en Suramérica en el año de 1956, y como su nombre lo indica (Provisional) fue implementado para dar soluciones emergentes de la época, el cual está conformado por los siguientes parámetros:

- ❖ Elipsoide de referencia: Internacional de Hayford.

- ❖ Datum: La Canoa. Venezuela.
- ❖ Desviación de la vertical: $\xi_0=6.37''$; $\eta_0=-0.15''$

2.2. SISTEMAS DE REFERENCIA GEOCÉNTRICOS

Los sistemas de referencia geocéntricos quedan definidos por un sistema de ejes cartesianos ortogonales (X, Y, Z) que tiene como datum el centro de masas de la Tierra, el eje Z sigue la dirección del polo, el eje X descansa en el plano ecuatorial y el eje Y es ortogonal a los anteriores, por lo tanto es un sistema tridimensional de alcance mundial⁹.

2.2.1. SISTEMA DE REFERENCIA GEOCÉNTRICO PARA LAS AMÉRICAS (SIRGAS)

La definición del sistema SIRGAS fue basada en las convenciones establecidas por el Sistema Internacional de Referencia Terrestre (ITRS por sus siglas en inglés), el cual se materializa en el Marco Internacional de Referencia Terrestre (ITRF por sus siglas en inglés) y utiliza el elipsoide GRS80 (Geodetic Reference System 1980) como referencia para coordenadas geodésicas. La primera realización de SIRGAS, se hizo coincidir con la materialización del ITRF94 época 1995.4 con un total de 58 estaciones observadas en simultáneo con el apoyo de los países de Sudamérica, quedando establecido el sistema SIRGAS95. A partir de este, se realizaron nuevas observaciones en el año 2000 con 184 estaciones correspondientes al ITRF2000 y época 2000.4, la cual se la denominó SIRGAS00, y finalmente la última realización de SIRGAS es la red que opera de forma continua con 250 estaciones, la misma que se denomina SIRGAS-CON¹⁰.

El sistema SIRGAS soporta las nuevas tecnologías de posicionamiento satelital dando la oportunidad de georreferenciar los levantamientos, mediciones y ajustes en un sistema homogéneo y de mayor cobertura. Además es preciso señalar que la evolución de la exactitud del geocentro entre WGS84 e ITRF alcanzó una diferencia mínima en el año 2000, por lo cual para fines cartográficos esta diferencia es despreciable para coordenadas obtenidas en WGS84 e ITRF2000¹¹.

⁹ Pallejá, E., Comité Nacional de la Unión geodésica y Geofísica Internacional, "Sistemas Geodésicos", 1999.

¹⁰ Página web Oficial de SIRGAS, www.sirgas.org, Fecha de ingreso, enero 2013.

¹¹ Tierra, A., "Estado actual del cambio para el Sistema de Referencia Geocéntrico SIRGAS95 en el Ecuador", 2007.

En la figura 2.1, se ilustra los sistemas antes mencionados PSAD56 y SIRGAS, en donde se observa la diferencia entre un sistema topocéntrico y geocéntrico, además de la heterogeneidad de ambos sistemas en cuanto se refiere a paralelismo y escalamiento.

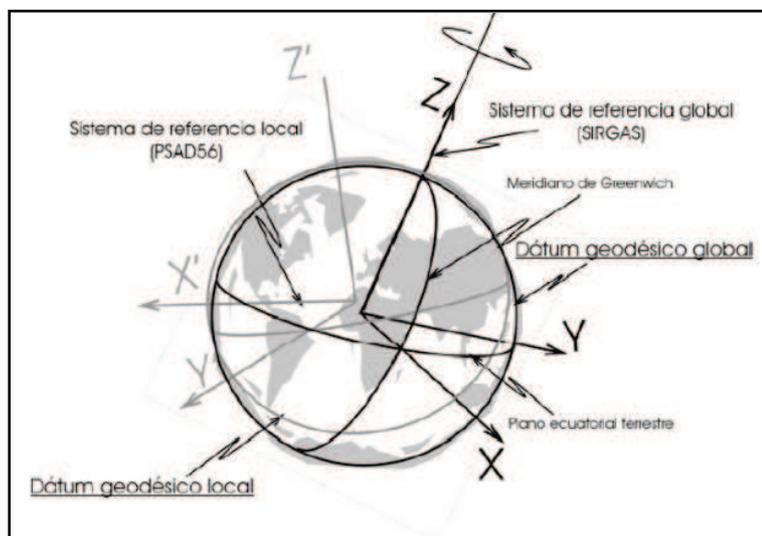


Figura. 2.1. Diferencia entre un sistema topocéntrico y geocéntrico

Fuente: UNLP - Facultad de Ciencias Astronómicas y Geofísicas, 2012

2.3. SISTEMAS DE PROYECCIÓN CARTOGRÁFICA

Los sistemas de proyección sirven para representar en un plano la Tierra o parte de ella, manteniendo una relación biunívoca entre las coordenadas de la superficie que será proyectada y las coordenadas del elipsoide al que está referida dicha superficie¹², esta relación se la puede expresar de la siguiente manera:

$$x = f_1(\varphi, \lambda)$$

2.1.

$$y = f_2(\varphi, \lambda)$$

Donde (x, y) representan las coordenadas planas deducidas a partir de las coordenadas elipsoidales (φ, λ) utilizando la función matemática especificada por cada sistema de proyección, obviamente estos sistemas de proyección generan distorsiones en las distancias y ángulos durante la transformación por lo cual se busca que el modelo matemático mantenga las mínimas discrepancias entre distancia y ángulos en la región de

¹² Molina, L., "Validación de modelos de transformación bidimensional para compatibilizar bases cartográficas escala 1:10000", Curitiba, 2007.

validez de la proyección¹³. Entre los tipos de sistemas de proyección se puede citar los que se detallan en la tabla 2.1.

Tabla. 2.1. Clasificación de los sistemas de proyección cartográfica

A. En función de la superficie sobre la que se proyecta	<ul style="list-style-type: none"> - Proyección cilíndrica - Proyección cónica - Proyección Azimutal
B. En función de la superficie sobre la que se proyecta con respecto al eje de la Tierra	<ul style="list-style-type: none"> - Proyección normal - Proyección transversa - Proyección oblicua - Proyección polar - Proyección ecuatorial
C. En función de las deformaciones	<ul style="list-style-type: none"> - Proyección conforme - Proyección equivalente - Proyección equiárea - Proyección equidistante - Proyección afiláctica
D. En función de la posición del centro de proyección	<ul style="list-style-type: none"> - Proyección gnomónica - Proyección estereográfica - Proyección escenográfica - Proyección ortográfica
E. En función de la orientación del punto de vista	<ul style="list-style-type: none"> - Proyección polar - Proyección meridiana - Proyección cenital - Proyección azimutal

Fuente: IGM Ecuador, 2005

2.3.1. SISTEMA UNIVERSAL TRANSVERSAL DE MERCATOR (U.T.M.)

Es una proyección conforme usada en casi todo el mundo, el cual utiliza un cilindro transversal que está tangente con la línea ecuatorial y se lo hace coincidir con un meridiano central en donde se forma un sistema de coordenadas planas con el origen situado en la

¹³ Pallejá, E., "Sistemas Geodésicos de Referencia", 1ra edición, Comité Nacional de la Unión Geodésica y Geofísica Internacional, 1999.

intersección entre el ecuador y el meridiano central seleccionado. Algunas consideraciones de este sistema se enlistan a continuación.

- Es un cilindro secante entre las latitudes 80° N – 80° S, esto debido a que se generan distorsiones conforme se aumenta la latitud.
- Está dividido en 60 zonas de 6° de longitud cada una.
- El meridiano central es la semisuma de los meridianos de las fronteras.
- La numeración inicia en el meridiano 180° Este a partir del meridiano de Greenwich.
- El origen en el hemisferio norte tiene coordenadas Este-Norte (500 000; 0) m.
- El origen en el hemisferio sur tiene coordenadas Este-Norte (500000; 10 000000) m.
- Elipsoide de referencia es adoptado por cada región o país.

2.3.2. TRANSVERSA MERCATOR DE QUITO (T.M.Q.)

Es una modificación de la proyección transversa de Mercator, en donde se modifica el meridiano central y el factor de escala, además que solamente es aplicable para el Distrito Metropolitano de Quito, lugar donde se aplica la metodología en estudio. Los parámetros de la proyección TMQ se encuentran en la tabla 2.2.

Tabla. 2.2. Parámetros proyección TMQ.

Meridiano central	78° 30' 00"
Origen de latitudes	0° 0' 0"
Factor de escala	1.0004584
Falso Este	500 000 metros
Falso Norte	10 000000 metros
Zona	17 Sur modificada ($w77^{\circ}$ - $w80^{\circ}$)

Fuente: Distrito Metropolitano de Quito, 2007.

2.4. TRANSFORMACIONES ENTRE SISTEMAS DE REFERENCIA GEODÉSICOS

Existen varios métodos convencionales para transformar las coordenadas de un sistema a otro, entre las más conocidas se tiene, por ecuaciones de regresión múltiple y parámetros de transformación. La elección de cualquiera de estas alternativas para

transformar las coordenadas de un sistema a otro debe actualizar el marco geodésico mejorando la consistencia de la red y minimizando las distorsiones acumuladas en el tiempo, con el objetivo de evitar la obsolescencia de la antigua red para comparar y estandarizar los resultados¹⁴.

2.4.1. TRANSFORMACIÓN TRIDIMENSIONAL. MÉTODO DE HELMERT

Esta transformación es válida entre sistemas que cuentan con coordenadas cartesianas o geocéntricas (X, Y, Z) y los parámetros son calculados a partir de puntos comunes observados en ambos sistemas, en donde la calidad de los parámetros de transformación encontrados puede depender del entorno de validez y la calidad de los puntos de control¹⁵.

El modelo matemático para la metodología de Helmert toma en consideración 7 parámetros de transformación: 3 traslaciones, 3 rotaciones y un diferencial de escala:

$$[X_G] = (1 + \delta) \cdot [R_x] \cdot [X_T] + [T] \quad 2.2.$$

Donde:

$[X_G]$ y $[X_T]$, son las matrices que contienen las coordenadas cartesianas de los puntos comunes de los sistemas geocéntricos y topocéntricos, respectivamente.

$[R_x]$ y $[T]$, son las matrices de rotación y traslación, respectivamente.

δ : es el diferencial de escala.

Para la obtención de las coordenadas (X, Y, Z,) de un punto de un sistema topocéntrico como es el caso de PSAD56, es necesario conocer la altura elipsoidal que es calculada mediante la ondulación geoidal y la altura ortométrica, para lo cual se realiza el siguiente cálculo:

$$h = H + n \quad 2.3.$$

¹⁴ INEGI, *El cambio de Marco de Referencia Terrestre Internacional (ITRF) en México*, Abril, 2011.

¹⁵ Instituto Geográfico Agustín Codazzi, *Parámetros oficiales de transformación para migrar a MAGNA-SIRGAS la información existentes en Datum BOGOTÁ*, 2004.

Donde:

h = altura elipsoidal

H =altura ortométrica

n = ondulación geoidal

En el caso de Ecuador, al no contar con un geoide de precisión se pueden calcular las coordenadas cartesianas obviando la altura elipsoidal o tomando valores arbitrarios, teniendo en cuenta que la diferencia o error en la posición es afectada en el orden decimétrico por la variación de valores de la altura elipsoidal¹⁶.

Los requerimientos necesarios para esta metodología es emplear por lo menos 3 puntos comunes entre ambos sistemas para obtener un sistema de 9 ecuaciones con 7 incógnitas. En la figura 2.2 se observa como actúa los 7 parámetros en la transformación de Helmert.

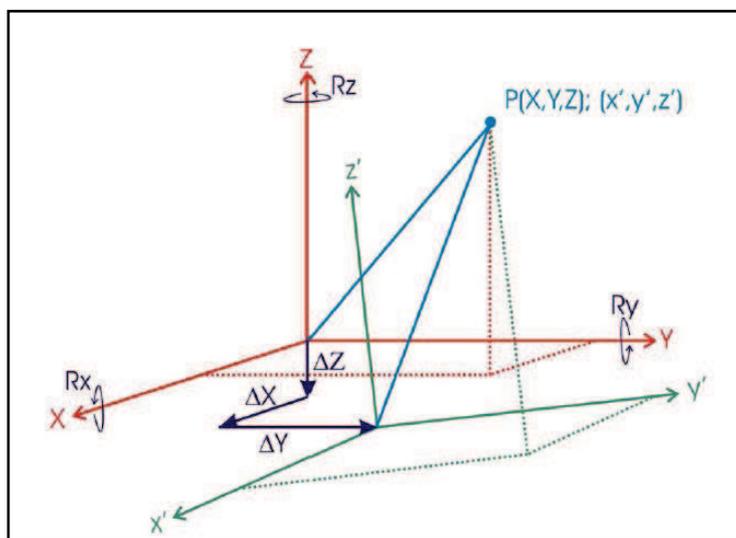


Figura. 2.2. Transformación de Helmert

Fuente: Instituto Geográfico Agustín Codazzi, 2004

¹⁶ Escalona, P., & Iturra, S., "Análisis de la metodología de transformación de PSAD56 a SIRGAS en el catastro minero de la zona de Til-Til", 2006.

Según (Rodríguez et al, 1997)¹⁷, algunos problemas que se suscitan en esta transformación es cuando la calidad de los puntos de control del sistema clásico son deficientes, generando 2 tipos de errores fundamentales:

- El primero definido por el comportamiento estadístico aleatorio que se puede solventar empleando mayor cantidad de puntos de control.
- El segundo es la propagación sistemática de errores, por el hecho que no son suficientes los 7 parámetros de transformación.

2.4.2. TRANSFORMACIÓN BIDIMENSIONAL CONFORME

La transformación bidimensional conforme es una derivación del método de Helmert y como es evidente en su nombre, es empleada para coordenadas planas, en este caso (Este-Norte) en donde se calculan 4 parámetros de transformación: 2 traslaciones, 1 rotación y 1 factor de escala, además es imprescindible conocer al menos 3 puntos comunes en ambos sistemas. Lo destacado de esta transformación es que no varía la verdadera forma de la superficie después de la transformación¹⁸. En la siguiente ecuación se observan las ecuaciones de condición para la transformación conforme bidimensional.

$$E_s = a \cdot E_p + b \cdot N_p + T_E$$

2.4.

$$N_s = a \cdot N_p - b \cdot E_p + T_N$$

Donde:

(E_s, N_s) y (E_p, N_p) , son las coordenadas proyectadas Este-Norte del sistema SIRGAS y PSAD56, respectivamente.

a y b , son parámetros para calcular el factor de escala y el ángulo de rotación, como se aprecia en la ecuación 2.5.

¹⁷ Rodríguez, R., Brunini, C. & Olondriz, J., "El problema de la determinación de parámetros de transformación", Universidad Nacional de la Plata, 1997.

¹⁸ Pérez, J., "Apuntes de Fotogrametría II", Mérida, 2001.

$$k = (1+\delta) = \sqrt{a^2+b^2}$$

2.5.

$$\text{tg } \alpha = b/a$$

Donde:

k = factor de escala, calculado a partir del diferencial de escala (δ).

α = ángulo de rotación

En la figura 2.3. se ilustra la transformación bidimensional conforme entre 2 sistemas, para calcular las coordenadas de un punto.

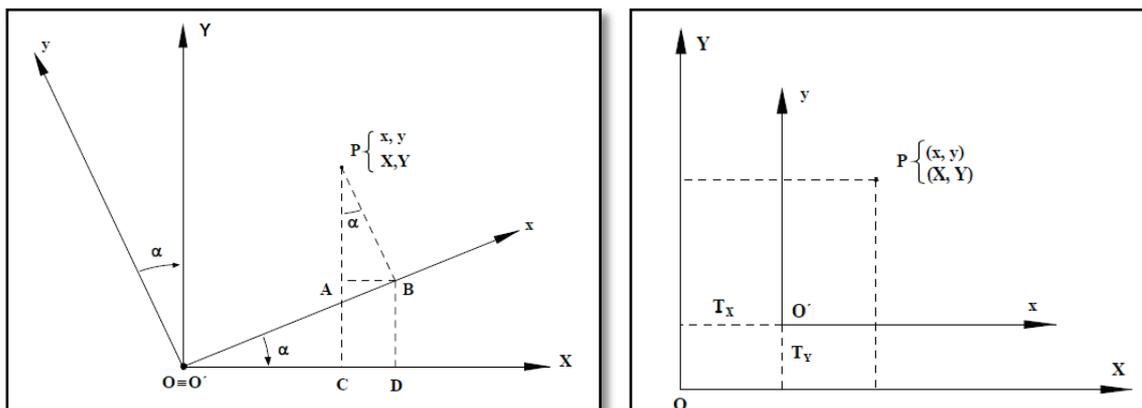


Figura. 2.3. Transformación bidimensional de Helmert

Fuente: Pérez J., 2001

Esta metodología considerada, genera fuertes errores sistemáticos, y su entorno de validez es para cubrir áreas pequeñas además que los parámetros obtenidos son exclusivamente para ese sector, impidiendo su extrapolación, por lo que se requiere de una zonificación de parámetros de transformación, es decir, cada sector o zona de estudio tengan su propios parámetros ¹⁹, si se desea extender a mayores superficies de territorio. A pesar de estas limitantes, se demostró que empleando esta transformación bidimensional se pueden alcanzar buenos resultados para transformar la cartografía de escalas menores a 1:5000²⁰.

¹⁹ Pérez, R., “Parámetros de transformación entre el Sistemas SIRGAS95 y los sistemas locales CDM y ROU-USAMS ”, 2002, pág. 5-6.

²⁰ Romero R. & Tierra A., “Parámetros de Transformación entre Sistemas de Referencia Proyectados UTM-PSAD56 y UTM-SIRGAS00 para escalas catastrales: Caso Distrito Metropolitano de Quito”,2012.

2.5. AJUSTE DE MÍNIMOS CUADRADOS

El ajuste de mínimos cuadrados se fundamenta en que se asume que el valor más probable de una variable es el valor que hace la suma de los cuadrados de los residuos sea mínima, para lo cual se debe minimizar la siguiente función.

$$\Phi = V^T P V \quad 2.6.$$

Donde se aprecia claramente que la función (Φ) es el producto matricial de los vectores residuales del ajuste (V), multiplicados por la matriz de pesos (P). Uno de los métodos empleados en este ajuste es el de las observaciones ajustadas (L_a) en función de las variables ajustadas $F(X_a)$, más conocido como el método paramétrico, que se fundamenta en la formulación de ecuaciones de condición²¹, como se indica en la ecuación 2.7.

$$L_a = F(X_a) \quad 2.7.$$

En donde es necesario calcular las variables ajustadas (X_a) mediante la suma de los valores aproximados de los parámetros desconocidos (X_o) y los parámetros calculados (X), de la siguiente forma:

$$X_a = X_o + X \quad 2.8.$$

De esta manera se calcula el vector de las observaciones ajustadas, aplicando el método de mínimos cuadrados

$$L_a = L_b + V \quad 2.9.$$

Donde,

L_b = vector de observaciones realizadas

V = vector de valores residuales

²¹ Passos, G., "Formación Continua en Georreferenciación aplicada al catastro rural", 2005.

Los valores de X_0 son estimaciones que se pueden hacer por métodos gráficos o datos preliminares que se posea, mientras que los valores del vector X se calculan a partir del modelo de linealización de observaciones indirectas del modelo matemático de mínimos cuadrados que se presenta a continuación.

Al reemplazar 2.7 en 2.9, se tiene:

$$F(X_a) = L_b + V \quad 2.10.$$

De esta manera se obtiene:

$$F(X_a) = L_b + V = F(X_0 + X) = F(X_0) + \left. \frac{\partial F}{\partial X_a} \right|_{X_0} \cdot X \quad 2.11.$$

De 2.11 se entiende que

$$F(X_0) = L_0 \quad 2.12.$$

$$\left. \frac{\partial F}{\partial X_a} \right|_{X_0} \cdot X = AX \quad 2.13.$$

Donde,

L_0 = vector de las observaciones aproximadas de los parámetros aproximados X_0 .

A = matriz de las derivadas parciales de las ecuaciones de condición o también conocido como Jacobiano.

Por lo tanto se puede expresar 2.11 de la siguiente manera:

$$L_b + V = L_0 + AX \quad 2.14.$$

Obteniendo el modelo linealizado de las observaciones del método paramétrico

$$AX - L = V \quad 2.15.$$

Donde,

L = Diferencia entre las observaciones realizadas de las observaciones aproximadas

Desde 2.15 se puede aplicar el principio de mínimos cuadrados, representada en 2.16 para calcular matricialmente el valor del vector X, dando como resultado que,

$$X = (A^T P A)^{-1} (A^T P L) \quad 2.16.$$

Al terminar el ajuste se procede a calcular la varianza a posteriori que es un estimador de la calidad del ajuste, para lo cual se puede calcular en función de los residuos como se aprecia a continuación

$$\hat{\sigma}^2 = \frac{V^T \cdot P \cdot V}{n-u} \quad 2.17.$$

Donde,

n= número de ecuaciones de condición

u= número de parámetros

Finalmente se calcula la matriz de varianza-covarianza de las observaciones ajustadas para conocer las precisiones de las mismas, de la siguiente manera:

$$\Sigma Xa = \hat{\sigma}^2 \cdot (A^T \cdot P \cdot A)^{-1} \quad 2.18.$$

2.6. REDES NEURONALES ARTIFICIALES

Las redes neuronales artificiales (RNA), aparecen como solución a la representación del conocimiento en el campo de la Inteligencia Artificial (IA), que era típicamente representado por redes y reglas semánticas o modelos probabilísticos, pero fueron apareciendo problemas más complejos que no podían expresar el conocimiento tan explícitamente, ni procesarlo, ni tampoco empleando razonamiento lógico. Es así que se decide emplear unidades computacionales procesadoras de información en forma paralela e interconectadas entre sí, similar a las neuronas biológicas, de esta manera se implementó las redes neuronales artificiales²².

²² Salao, J., "Estudio de las técnicas de Inteligencia Artificial mediante el apoyo de un software educativo", 2009.

2.6.1. NEURONA BIOLÓGICA

La neurona biológica recibe señales por medio de la sinápsis que se origina en las dendritas o membrana celular las cuales son emisoras de la señal proveniente de otra neurona, si la señal recibida es lo suficientemente fuerte es capaz de activar la neurona y emitir un flujo de información a través del axón que enviará a otra neurona siguiendo el mismo proceso explicado. En la figura 2.4 se ilustra este proceso.

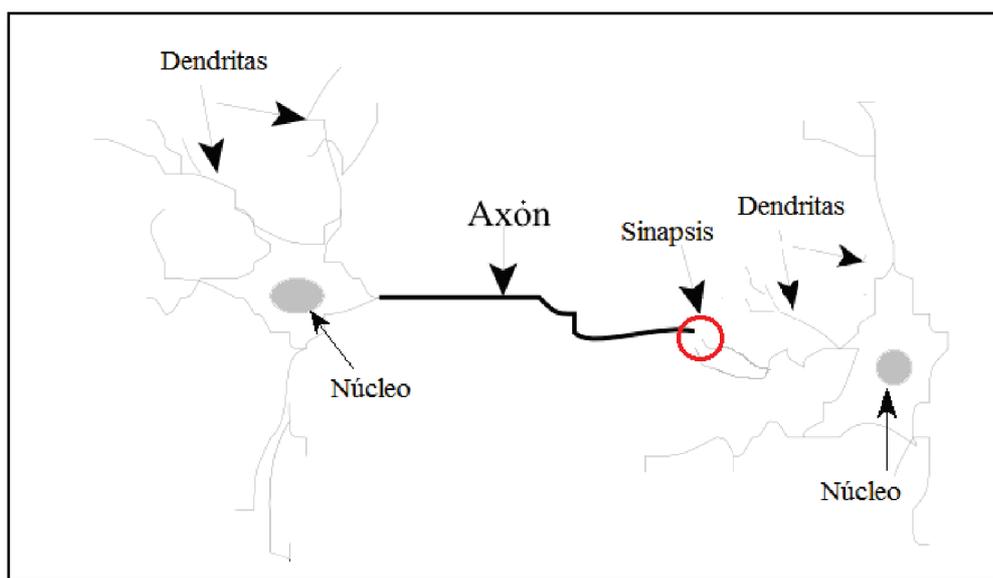


Figura. 2.4. Proceso de sinapsis de una neurona biológica

Fuente: Gershenson C, 2003.

2.6.2. FUNDAMENTOS BIOLÓGICOS

Una red neuronal artificial intenta simular las estructuras biológicas del sistema nervioso, tomando en cuenta que el cerebro es un superprocesador complejo, no lineal y paralelo con alrededor de 10^{11} neuronas y 10 veces más de conexiones 10^{12} , las cuales tienen la capacidad de:

- Recuperar la información y realizar las tareas que anteriormente lo hacían neuronas muertas, es decir, se autorecuperan.
- Construir sus propias reglas de aprendizaje a través de la experiencia (conocimiento adquirido).

- Realizar cálculos muy complejos en paralelo como la visión que es un proceso cerebral realizado en muy corto tiempo.
- Son responsables de la memoria o inteligencia que no es mas que el acceso al conocimiento.

2.6.3. SEMEJANZAS ENTRE NEURONAS BIOLÓGICAS Y NEURONAS ARTIFICIALES

La semejanza está determinada en las entradas (sinapsis) que son multiplicadas por pesos (fuerza de las señales sinápticas) y calculadas por una función de sumatoria que determina la activación de la neurona. Finalmente otra función matemática (señal que viaja por el axón) calcula la señal de salida de la neurona hacia otra neurona interconectada que recibirá la señal y de esta forma se da origen a una nueva sinapsis. En la figura 2.5 se observa esta semejanza entre neuronas biológicas y artificiales, donde se aprecia claramente que las entradas (E) de la neurona artificial cumplen con la función de las dendritas de una neurona biológica, mientras que el cuerpo celular de la neurona corresponden a la sumatoria de las entradas (Σ) y la función de activación ($f(\cdot)$), finalmente la señal de salida de la neurona artificial corresponde al impulso de activación que viaja a través del axón para realizar la sinápsis con otra neurona.

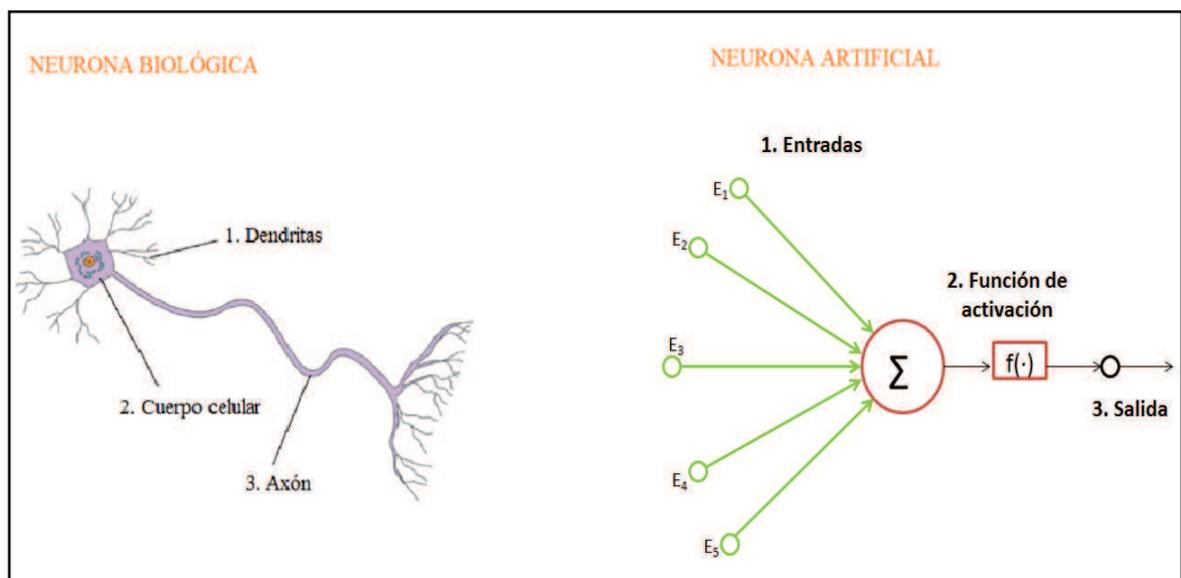


Figura. 2.5. Semejanza entre una neurona biológica y una neurona artificial

Es preciso señalar también que estas semejanzas están basadas en algunas funciones cerebrales tales como²³:

- Se auto organiza de manera que crea su propia representación de la información.
- Tolera fallos, como se explicó anteriormente es capaz de suplir actividades de neuronas dañadas.
- Tiene la capacidad de generalizar.
- Los procesos de aprendizaje de la RNA derivan en conocimiento adquirido cuando la red es estimulada por el ambiente que la rodea.
- Las dendritas son las portadoras del conocimiento adquirido (memoria) en los procesos de aprendizaje.

2.6.4. ELEMENTOS BÁSICOS DE UNA RED NEURONAL ARTIFICIAL

Al igual que en el cerebro humano, la neurona es el elemento principal de una red neuronal artificial, de igual manera el elemento fundamental de una red neuronal artificial es la neurona artificial, por lo tanto, para ejemplificar su funcionamiento, se presenta en la figura 2.6 una neurona artificial, en donde se observa que la suma de las n entradas (x_j) de la neurona i , multiplicada por los pesos sinápticos (w_{ij}), genera la entrada ponderada total o potencial postsináptico de la neurona i . La función de los pesos sinápticos es medir la fuerza de interconexión entre las neuronas enlazadas, posterior a esto se observa que la sumatoria de las señales del potencial postsináptico más el umbral (θ_i) deben pasar por una función de activación o de transferencia ($f(\cdot)$), obteniendo la señal de salida (y_i) de la red neuronal.

²³ Daza, S., Redes neuronales, <http://www.monografias.com/trabajos12/redneur/redneur.shtml>, 2008-10, 2012-10

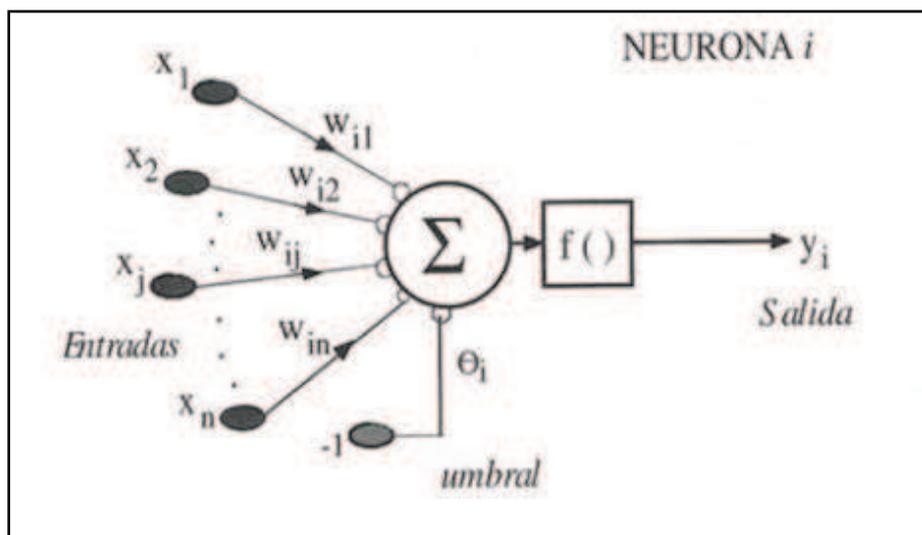


Figura. 2.6. Modelo de una neurona artificial

Fuente: Nacelle A., 2009

El funcionamiento de la neurona (i), ilustrada en la figura anterior y explicada anteriormente, también se puede expresar como modelo matemático de la siguiente forma.

$$y_i = f\left(\sum w_{ij} \cdot x_j - \theta_i\right) \quad 2.19.$$

Finalmente se puede resumir que la estructura interna general de una RNA queda conformada por los siguientes elementos:

- El conjunto de capas donde se puede encontrar la capa de neuronas de entradas que se le presenta a la red para iniciar con el entrenamiento, la capa de neuronas ocultas que reciben la información de capas anteriores y la envían a la capa de salida.
- Los pesos sinápticos que son aleatorios y se ajustan en función de los algoritmos de aprendizaje.
- Un elemento externo de cada una de las entradas de la red que cumple la función de aumentar o disminuir el valor de la señal ponderada o postsináptica, la cual se denomina umbral.
- El sumador lineal que es el encargado de enviar las señales postsinápticas más el umbral a la función de activación de la red.

- La función de activación o de transferencia que por lo general es determinista y en la mayoría de los casos es creciente y continua; mas adelante se verá un apartado sobre funciones de activación.
- La señal que origina la función de activación es la respuesta de la red que se transmitirá al exterior.

Es preciso indicar aspectos prácticos para lectores que desean familiarzarse con redes neuronales artificiales que ven la necesidad de comprender su funcionamiento, por tal motivo en el anexo 1 se encuentra un ejercicio práctico que trata principalmente sobre las variaciones aleatorias de los pesos sinápticos y la función de los umbrales, ejercicios como este, que sirven de iniciación en el conocimiento de redes neuronales se lo puede encontrar a mayor detalle en (Gershenson, C., 2003²⁴).

2.6.5. PROCESOS DE APRENDIZAJE DE UNA RNA

El aprendizaje de una red neuronal artificial no es mas que la solución de un problema mediante un proceso en el cual los parámetros libres (pesos sinápticos) de la red se adaptan a las modificaciones que ocurren en la estructura interna de la red y en el ambiente que la estimula, a este proceso se lo denomina como algoritmo de aprendizaje. Con esto se puede decir que una red neuronal con el tiempo puede aprender las propiedades del ambiente con la que interactúa y las características de los datos que se le presentan.

El objetivo del aprendizaje es mejorar el rendimiento de la red en función de la señal de error que se origina en la salida de la red, esto se hace en función del ajuste de los pesos hasta lograr que se estabilicen. La estabilización es cuando la red almacena en sus conexiones la información o dicho de otra manera se guarda en la memoria, tal como se mencionó en el apartado 2.6.3. Es importante recordar que una de las particularidades de las redes neuronales es la capacidad de generalizar, es decir, que proporciona respuestas similares con diferentes conjuntos de entrada de manera que se la pueda emplear en cualquier circunstancia, pero si la red memoriza los patrones de entrada que se utilizó en

²⁴ Gershenson, C., “Artificial Neural Networks for beginners”, 2003.

un principio (entrenamiento) y los emplea para dar una respuesta a pesar de cambiar los valores de entrada, se dice que la red tiene un sobreaprendizaje y pierde la capacidad de generalizar²⁵, en la figura 2.7 se puede observar como se produce el aprendizaje y sobreaprendizaje de una red. Para ayudar a mitigar el efecto del sobreaprendizaje se necesitan 3 conjuntos de datos de entrada y salida, los cuales se distribuyen de la siguiente manera:

- Datos de entrenamiento que son usados en la fase inicial del aprendizaje, en donde se le presenta a la red las entradas y las salidas esperadas.
- Datos de validación, los cuales se le presenta a la red con los eventos más extremos (valores máximo y mínimos) para mejorar la capacidad de generalización de la red, de esta manera se intenta garantizar un buen entrenamiento²⁶.
- Datos de test los cuales deben estar valores aleatorios sin ningún sesgo en especial que representen el problema en cuestión.

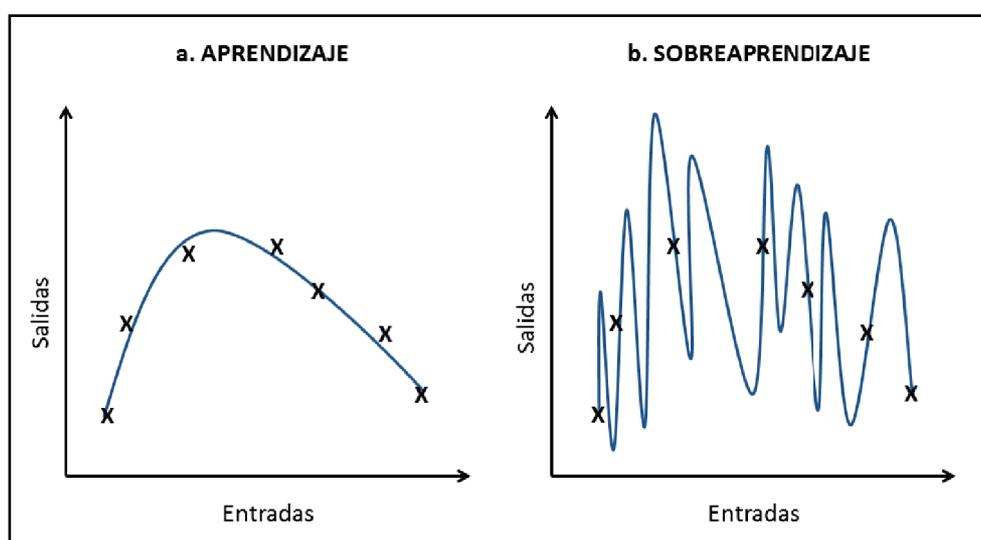


Figura. 2.7. Generalización por Aprendizaje (a), Sobreaprendizaje (b)

²⁵ Chacón, A., "Predicción de ondulaciones geoidales a través de una red neuronal artificial en un área del Distrito Metropolitano de Quito", 2010.

²⁰ Najah, A., El-Sahfie, A., Karim, O. & El-Sahfie H., "Application of artificial neural networks for water quality prediction", 2012.

2.6.6. TIPOS DE APRENDIZAJE

Según Nacelle A.,²⁷ se puede diferenciar los procesos de aprendizaje en función de la modificación de la estructura interna de la red y de los cambios iterativos de las conexiones sinápticas como se demuestra a continuación:

- **APRENDIZAJE SUPERVISADO**

El aprendizaje supervisado se da cuando se le presenta a la red un conjunto de datos de entrada que serán usados para calcular una respuesta al problema presentado, esta respuesta es comparada con un conjunto similar de datos de salida y, la diferencia que se obtenga entre la respuesta de la red y la respuesta deseada se constituye en la función de error, es en este punto donde interviene un agente externo de la red (supervisor) que se encarga de determinar las modificaciones de los pesos sinápticos hasta minimizar el error.

- **APRENDIZAJE NO SUPERVISADO O AUTOORGANIZADO**

En este aprendizaje no es necesaria la presencia de un agente externo para ayudar a la red a mejorar su rendimiento, la misma red mediante el algoritmo de aprendizaje seleccionado ajusta los pesos de las capas de entrada y ocultas, de manera que, solamente se le presenta a la red un conjunto de datos de entrada y no de salida deseada para la comparación. Este tipo de aprendizaje es utilizado en redes neuronales que tendrán el objetivo de relacionar, clasificar o reconocer patrones que se encuentran implícitamente en los datos de entrada.

- **APRENDIZAJE HÍBRIDO**

Se da este aprendizaje cuando la red presenta las características de los aprendizajes antes señalados, pero en diferentes capas de la red neuronal.

- **APRENDIZAJE REFORZADO**

A diferencia del aprendizaje híbrido, este toma funcionalidades del aprendizaje supervisado y no supervisado para mejorar la respuesta, en el caso del supervisado lo que

²⁷ Nacelle, A., "Redes Neuronales Artificiales", 2009

hace es indicar si el rendimiento global de la red está actuando bien o no, así el supervisor envía un señal de aprobación o negación y, en el caso del aprendizaje no supervisado, ajusta los pesos en función de probalidades y no se basa en respuestas deseadas.

2.6.7. FUNCIONES DE ACTIVACIÓN O DE TRANSFERENCIA

Como se mencionó anteriormente, la función de activación es monótona, continua, creciente y en la mayoría de los casos es derivable en todos sus puntos. Es la encargada de limitar la amplitud de la señal proveniente de las capas precedentes de la red neuronal, la misma que se encarga de activar o desactivar la señal que se emitirá a capas posteriores de la red, a esto se denomina el estado de activación.

En definitiva, el estado de activación es un valor numérico asociado a la neurona que dependiendo de la función puede variar su rango entre [-1,1] y [0,1]. Entre las funciones de activación comunmente empleadas (ver figura 2.8.) se tiene:

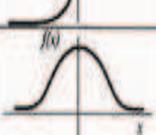
	Función	Rango	Gráfica		Función	Rango	Gráfica
Identidad	$y = x$	$[-\infty, +\infty]$		Sigmoidea	$y = \frac{1}{1+e^{-x}}$ $y = \tanh(x)$	$[0, +1]$ $[-1, +1]$	
Escalón	$y = \text{sign}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$		Gaussiana	$y = Ae^{-bx^2}$	$[0, +1]$	
Lineal a tramos	$y = \begin{cases} -1, & \text{si } x < -1 \\ x, & \text{si } -1 \leq x \leq 1 \\ +1, & \text{si } x > 1 \end{cases}$	$[-1, +1]$		Simusoidal	$y = A \text{sen}(\omega x + \phi)$	$[-1, +1]$	

Figura. 2.8. Funciones de activación más empleadas

Fuente: Nacelle A., 2009

2.6.8. ARQUITECTURA DE REDES NEURONALES ARTIFICIALES

La clasificación de las redes neuronales en función de su arquitectura se basa en el número de capas que contenga la red, por ejemplo:

- **Redes monocapa:** es la forma más fundamental de representar una red neuronal artificial, debido a que contiene en su estructura una sola capa, es decir, las neuronas de la capa de entrada que se conectan completa y directamente con la capa de salida.
- **Redes Multicapa:** La característica principal de estas redes es la presencia de una o más capas ocultas que procesan la información recibida por la capa de entrada que está en constante interacción con el entorno, este tipo de red puede estar total o parcialmete conectada.
- **Redes recurrentes:** Las conexiones de este tipo de redes pueden ser entre neuronas de la misma capa, de diferentes capas o con la misma neurona , por lo que es empleada para el estudio de sistemas no lineales. Para una mejor ilustración, en la figura 2.9 se encuentran ejemplos de arquitecturas de redes neuronales artificiales.

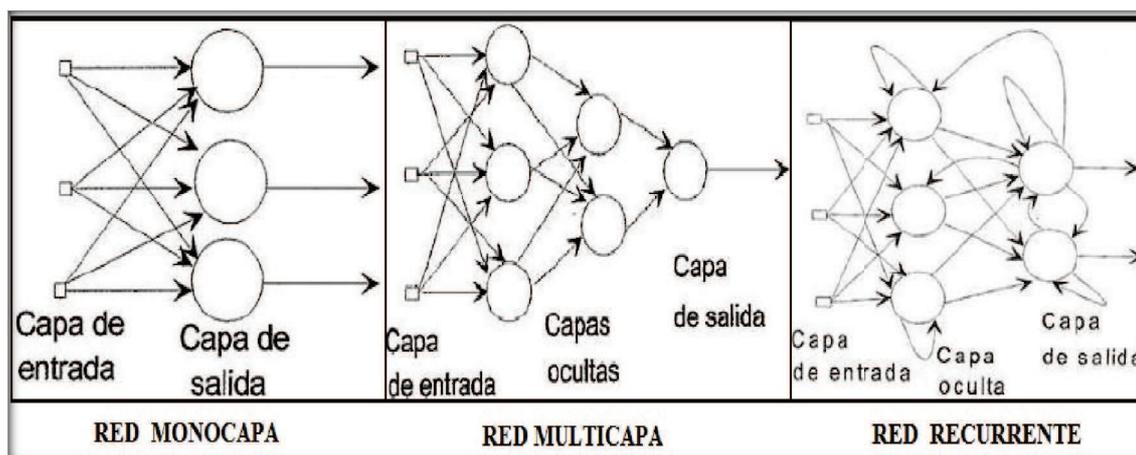


Figura. 2.9. Arquitecturas comunes de redes neuronales artificiales

Fuente: Nacelle A. (2009)

Otro aspecto importante al elegir la arquitectura de la red, es conocer el tipo de conexión que tendrán las capas, con esto se quiere decir que el sentido de transmisión de la señal será determinante para elegir el algoritmo de aprendizaje, mantener las propiedades de generalización y adaptación a los cambios tanto internos como externos de la red. En este contexto se puede mencionar los siguientes tipos:

- **Redes unidireccionales (feedforward):** como su nombre lo indica, la señal transita a través de la red en una sola dirección (izquierda-derecha) y las conexiones son

únicamente desde la capa de entrada hacia la capa de salida, pasando por las capas ocultas.

- **Redes retroalimentadas (feedback):** Tienen la particularidad que el tránsito de la señal a lo largo de la red se puede dar desde la capa de entrada hacia la capa de salida o viceversa, y las conexiones se dan en cualquier sentido.

2.7. REDES NEURONALES ARTIFICIALES MULTICAPA (RNAM)

Las redes neuronales multicapa son redes unidireccionales, supervisadas, conformadas por una o más capas ocultas que usan el algoritmo de retropropagación como gradiente descendiente (o sus modificaciones) como proceso de aprendizaje, frecuentemente empleadas como aproximadoras universales de funciones²⁸, y recientemente relacionadas con problemas de reconocimientos de patrones, predicciones y comparaciones enfocadas en el modelamiento de problemas complejos no lineales en ciencias de la tierra²⁹, por tal razón se ha empleado esta arquitectura para el presente trabajo.

Por lo general, se aplica una función de activación sigmoideal con sus diferentes variaciones (logística y tangente hiperbólica) en las capas ocultas y una función lineal en la capa de salida, la función sigmoideal tiene su razón de ser en que la red debe aprender las relaciones no lineales existentes entre los conjuntos de entradas y salidas, mientras que la función lineal se interpreta como función de regresión entre las entradas y salidas, por lo que la señal que ingresa a la función de activación lineal es la misma señal que se emite al ambiente, como lo ilustra la figura 2.10.

²⁸ Hernández, N., "Redes de Neuronas Artificiales en Oceanografía", 2004.

²⁹ Rezeai, K., et al., "Feed Forward Neural Network and Interpolation Function Models to Predict the Soil and Subsurface Sediments Distribution in Bam, Iran", 2009.

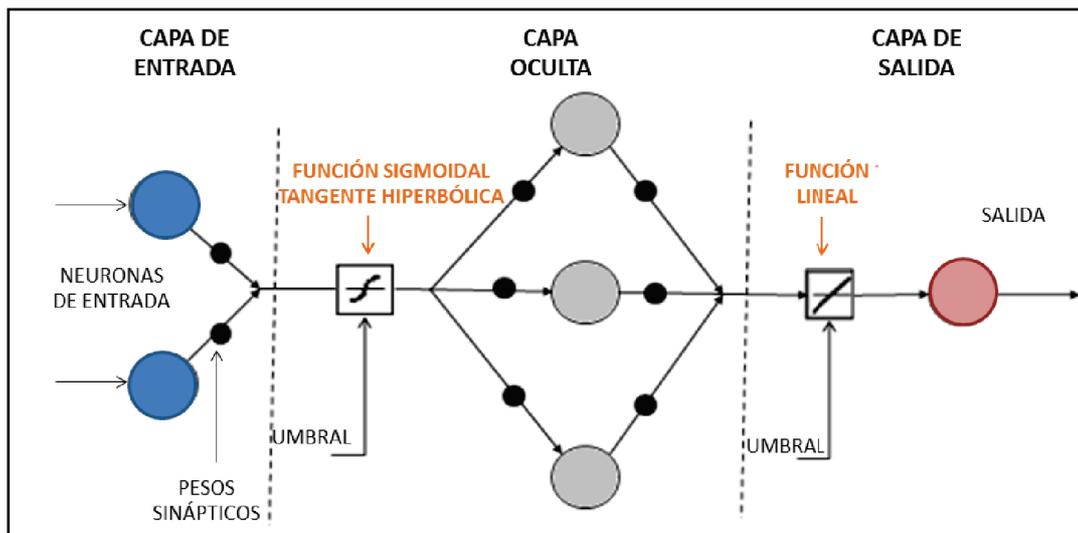


Figura. 2.10. Funciones de transferencia más usadas en una red neuronal artificial multicapa

En la anterior figura se observa claramente que en la capa oculta se utiliza la función de transferencia sigmooidal tangente hiperbólica, esta función es utilizada con frecuencia en redes neuronales artificiales, aunque actualmente no existen demasiadas investigaciones enfocadas a la correcta selección de una función de activación, se puede mencionar las razones por la cual esta función es considerada constantemente, haciendo resonancia del apartado 2.6.7 de este capítulo.

La función sigmooidal tangente hiperbólica es una función continua real, estrictamente creciente y acotada que cumple con la siguiente condición:

Sea S una función sigmoidea continua cuyos elementos son funciones reales tales que, $f(x) \in S, f(x), f: R \rightarrow R$, donde sus límites para $x \rightarrow \pm\infty$ son:

$$\begin{aligned} \lim_{x \rightarrow \infty} f(x) &= \alpha \\ \lim_{x \rightarrow -\infty} f(x) &= \beta \\ \text{con } \alpha &> \beta \end{aligned}$$

Donde,

$f(x)$ = función sigmooidal tangente hiperbólica

Los valores de $\alpha = 1$ y $\beta = -1$

Así mismo, esta función es considerada en esta técnica porque es diferenciable en todos sus puntos y además el valor de la primera derivada de la función (pendiente) tiene valor positivo lo cual facilita seguir el camino sobre la superficie del error³⁰, como se verá posteriormente.

Finalmente el criterio determinante para utilizar funciones sigmoideas, en este caso tangente hiperbólica, es por el hecho que presenta buenos rendimientos aplicados en funciones no lineales usando desde 5 neuronas en la capa oculta hasta 13 neuronas³¹.

2.7.1. ALGORITMO DE RETROPROPAGACIÓN (APRENDIZAJE VISTO COMO GRADIENTE DESCENDIENTE)

El algoritmo de retropropagación mejora el rendimiento de la red en función de la corrección de la señal de error usando el método del gradiente descendiente, este algoritmo hace que los pesos sinápticos adopten valores aleatorios al paso de la señal de activación dirigida hacia adelante, proveniente de la estimulación de las neuronas de entrada hasta obtener la señal de salida, en este punto se compara con la respuesta deseada para conocer el error (diferencia) y, finalmente la señal de propagación del error es enviada hacia atrás para ajustar los pesos hasta alcanzar un error mínimo (ver figura 2.11.), el proceso es iterativo y en cada iteración se actualizan los pesos y las conexiones sinápticas hasta que la red neuronal *aprenda* el entrenamiento. Este algoritmo desarrollado por Rumelhart, Hinton & Williams en 1986 es ampliamente utilizado en las redes multicapa debido a su simplicidad y aplicabilidad.

³⁰ Chandra, P., “Sigmoidal Function Classes for Feedforward *Artificial Neural Networks*”, 2003.

³¹ Llano, L. & et al, “Comparación del desempeño de funciones de activación en redes feedforward para aproximar funciones de datos con y sin ruido”, 2007.

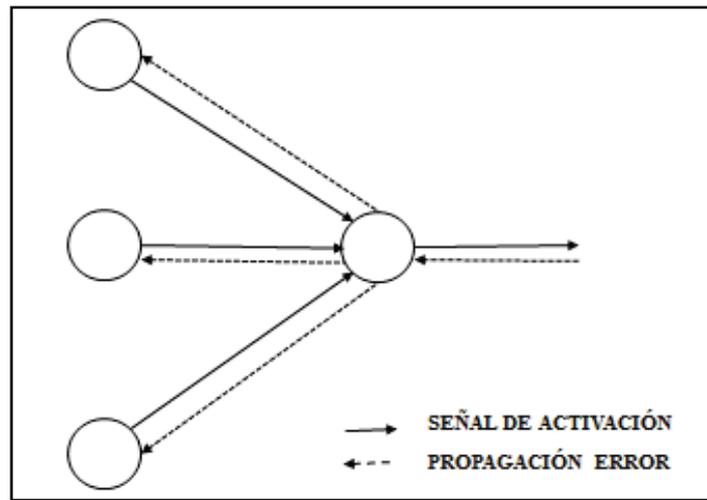


Figura. 2.11. Funcionamiento lógico del algoritmo de retropropagación

Fuente: Haykin S, 2005

La notación que se empleará en este tema, será definida por una red neuronal con neuronas de entrada (i), neuronas ocultas (j) y, neuronas de salida (k), además de los siguientes parámetros:

- Las neuronas serán representadas por el símbolo x .
- Las iteraciones o las veces que la señal de activación pasa por la red, es denominada como n .
- La señal de error proveniente de la neurona j en la n iteración es $e_j(n)$.
- La respuesta deseada de la neurona j es $d_j(n)$.
- La señal de salida de una neurona definida por el símbolo y .
- Los pesos sinápticos que conecta la neurona de entrada con la neurona oculta $w_{ji}(n)$, donde el primer subíndice indica la neurona a la que se envía la señal y el segundo subíndice representa la neurona de donde proviene la señal.
- El umbral aplicado a las neuronas ocultas denominado por b_j , en donde su efecto sináptico es $w_{j0} = b_j$.
- El campo local inducido o lo que es igual a la suma de la señal ponderada con el umbral antes de ser aplicada la función de transferencia es $v_j(n)$.
- La función de activación será $f(\cdot)$.

La señal de activación ponderada que se origina desde la capa de entrada de la RNAM viene dada por la ecuación 2.20.

$$u_j(n) = \sum x_i \cdot w_{ji}(n) \quad 2.20.$$

La ecuación 2.20 viene condicionada por el umbral que actúa como reguladora de la señal de activación originando el campo local inducido, que viene dado por:

$$v_j(n) = u_j(n) + b_j \quad 2.21.$$

$$v_j(n) = \sum w_{ji} \cdot y_i \quad 2.22.$$

Esta función del campo local inducido es la que ingresará a la función de transferencia para determinar la activación de la neurona, en este caso, la primera función que interviene es una sigmoideal tangente hiperbólica, como lo indican la ecuación 2.23.

$$f(\cdot) = \tanh(v_j(n)) = \frac{1 - e^{-v_j(n)}}{1 + e^{-v_j(n)}} \quad 2.23.$$

La ecuación 2.23, también se puede interpretar como el campo local inducido por una función de transferencia de la siguiente forma:

$$y_j = f(v_j(n)) \quad 2.24.$$

La expresión 2.24, es la señal de salida de la capa oculta, la cual será la entrada para la capa de salida. Como se mencionó anteriormente, la segunda función de transferencia que se encuentra en la capa de salida es una función lineal, lo cual indica que la misma señal que ingresa, es la que se emite al entorno como respuesta, por lo tanto se puede decir lo siguiente:

$$f_k(\cdot) = f_j(\cdot) = f(\cdot) \quad 2.25.$$

Por lo tanto,

$$y_k(n) = y_j(n) \quad 2.26.$$

En este caso el error de la señal de salida de la neurona j de la ecuación 2.26 en la época n , es comparada con la respuesta que se esperaba, obteniendo el error de la neurona de salida,

$$e_j(n) = d_j(n) - y_j(n) \quad 2.27.$$

El error de la capa de salida de la red es la semi-suma de los errores al cuadrado de las neuronas de salidas en la época de iteración n ,

$$E(n) = \frac{1}{2} \sum (e_j(n))^2 \quad 2.28.$$

Para comprender mejor la función del error de salida de la red neuronal, se puede observar la figura 2.12 con una ilustración de una RNA multicapa.

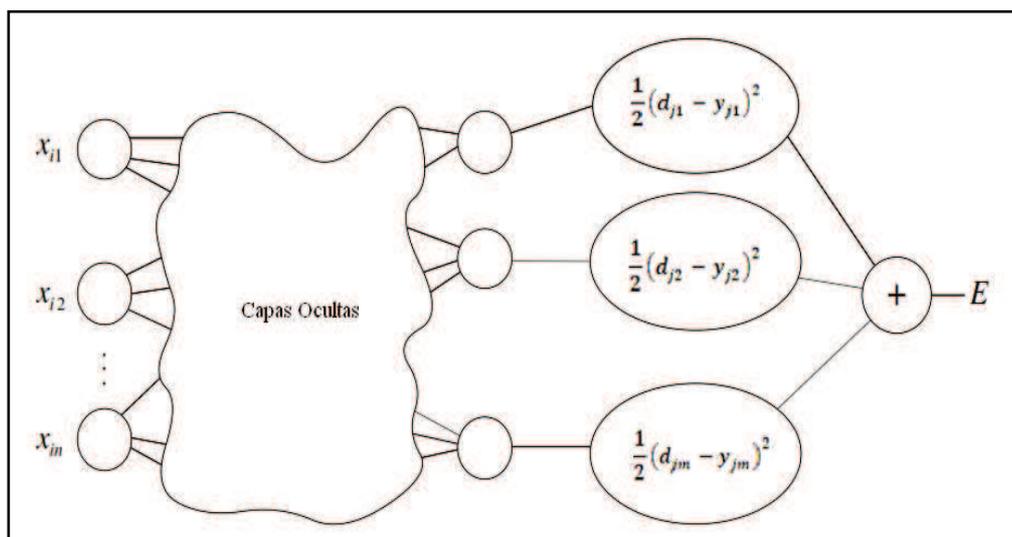


Figura. 2.12. Cálculo de la señal de error de una red neuronal multicapa

Fuente: Rojas R, 1996.

Una vez que se ha calculado la ecuación 2.28, la función del algoritmo de retropropagación es conocer la dependencia de la función de error con respecto a las entradas, salidas y pesos de la red, para lo cual se ajustan los pesos con el método del gradiente descendiente³², por lo que es necesario conocer el gradiente del error:

$$\Delta E = \left(\frac{\delta E}{\delta w_{1i}} + \frac{\delta E}{\delta w_{2i}} + \frac{\delta E}{\delta w_{3i}} + \dots + \frac{\delta E}{\delta w_{ji}} \right) \quad 2.29.$$

La actualización de los pesos se la realiza con la siguiente ecuación:

$$\Delta w_{ji} = -\eta \frac{\delta E(n)}{\delta w_{ji}} \quad 2.30$$

La expresión anterior puede ser interpretada como el ajuste de los pesos sinápticos que es igual al producto de una constante de aprendizaje (η) y el gradiente del error anterior calculado por la red. El ajuste dependerá de la constante η y de cuanto afecta los valores de los pesos al error, es decir, si los pesos influyen demasiado en el error, entonces el ajuste será más largo que si no influyera en gran cantidad. La alternativa para conocer lo antes expuesto y resolver la ecuación 2.30, es aplicando la regla de la cadena, la cual permite determinar el aporte de cada uno de los parámetros a la función de error.

$$\frac{\delta E(n)}{\delta w_{ji}} = \frac{\delta E(n)}{\delta e_j} \cdot \frac{\delta e_j}{\delta y_j} \cdot \frac{\delta y_j}{\delta v_j} \cdot \frac{\delta v_j}{\delta w_{ji}} \quad 2.31.$$

De las ecuaciones 2.28, 2.27, 2.24 y 2.22 se deriva respectivamente lo siguiente

$$\frac{\delta E(n)}{\delta e_j} = e_j(n) \quad 2.32.$$

$$\frac{\delta e_j}{\delta y_j} = -1 \quad 2.33.$$

$$\frac{\delta y_j}{\delta v_j} = f'(v_j(n)) \quad 2.34.$$

³² Gershenson, C., "Artificial Neural Network for beginners", 2003.

$$\frac{\delta v_j}{\delta w_{ji}} = y_i(n) \quad 2.35.$$

Reemplazando 2.32, 2.33, 2.34 y 2.35 en 2.31, se obtiene:

$$\frac{\delta E(n)}{\delta w_{ji}} = -e_j(n) \cdot f'(v_j(n)) \cdot y_i(n) \quad 2.36$$

Como se aprecia en la ecuación 2.36, la derivada parcial del error con respecto a los pesos sinápticos aporta el signo negativo o el sentido opuesto al gradiente del error de la ecuación 2.29, de ahí el nombre de gradiente descendiente.

Para entender mejor el proceso de corrección del error en una función sigmoideal se aprecia en la figura 2.13, que se quiere seguir la dirección del gradiente para encontrar el mínimo de esta función para lo cual es importante que no existan regiones donde la función de error sea completamente plana, por lo tanto, como la función sigmoideal siempre tendrá derivadas positivas, la pendiente de la función proporciona una función de descenso que se puede seguir³³.

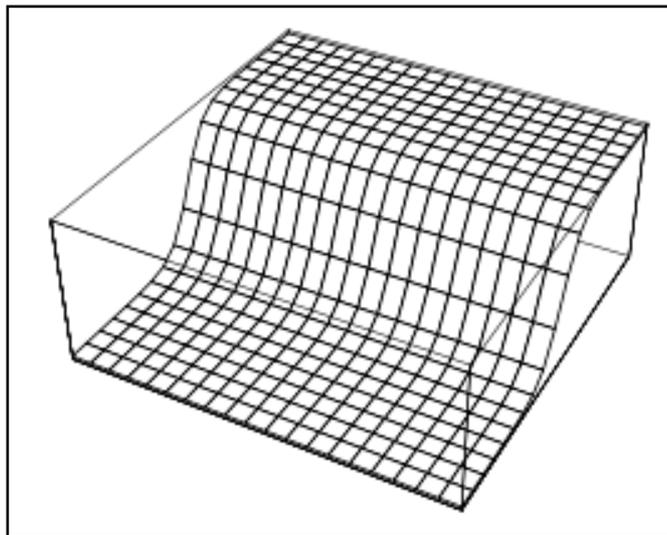


Figura. 2.13. Paso de la función de error en una función sigmoideal

Fuente: R. Rojas, 1993

³³ Rojas, R., "Neural Network. A systematic Introduction", 1996.

El problema que se presenta en el algoritmo de retropropagación en el momento de encontrar el camino adecuado del gradiente de error, es cuando este se encuentra en una superficie de mínimo local, esto ocurre porque el método de optimización que se emplea sigue las pendientes más pronunciadas, por lo tanto no se asegura que la función tendrá convergencia en óptimos globales³⁴, como se aprecia en la figura 2.14, obviamente que no se puede asegurar si el error se encuentra en una superficie de mínimo local o global, pero una vez que la red converge en un mínimo (local o global), se detiene el aprendizaje³⁵.

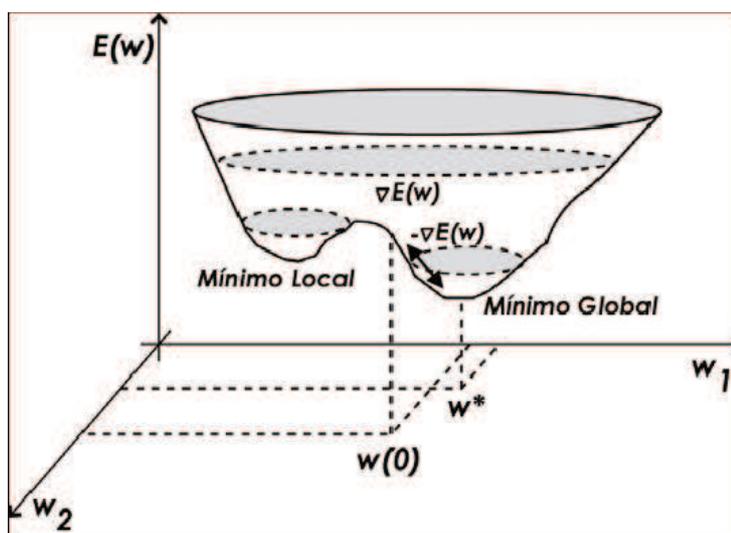


Figura. 2.14. Superficie de error en un mínimo local o global

Fuente: Chacón, 2010.

2.7.2. MÉTODO DE OPTIMIZACIÓN DE LEVENBERG- MARQUARDT

El algoritmo de aprendizaje de retropropagación en ocasiones puede ser lento e ineficiente por el hecho de que emplea la información de la primera derivada o el gradiente para encontrar el error, lo cual no garantiza que sea un mínimo global, por esta razón se han realizado variaciones de este algoritmo de aprendizaje para acelerar el proceso de entrenamiento y a su vez dar mayor confianza en ubicar el error en un mínimo global, para lo cual se emplean los criterios de segundas derivadas (matriz hesiana)³⁶, por lo tanto este método es considerado en la búsqueda del gradiente descendiente para el entrenamiento de la red como un proceso de optimización numérica, el cual fue desarrollado por Levenberg

³⁴ Hernández, N., "Redes de Neuronas Artificiales en Oceanografía", 2004.

³⁵ Chacón, A., "Predicción de ondulaciones geoidales a través de una red neuronal artificial en un área del Distrito Metropolitano de Quito", 2010

³⁶ Hwang, J., "Regression Modeling in Back-Propagation and Projection Pursuit Learning", 1994.

(1944) y Marquardt (1963), el mismo que consiste en la actualización de parámetros en n iteraciones, como se demuestra en la ecuación 2.37.

$$w_{ji}(n) = (w_{ji}(n) - 1) - [H(w_{ji}(n) - 1) + \eta(n)I]^{-1} \Delta w_{ji}(n) \quad \text{Ec.2.37}$$

Como se observa en la expresión anterior, para aplicar el algoritmo es necesario resolver la matriz inversa de $[H(w_{ji}(n) - 1) + \eta(n)I]^{-1}$, la misma que se puede expresar como la matriz Hessiana (\hat{H}) de la función total de error:

$$\tilde{H}(w_{ji}(n)) = \sum \left(\frac{\delta E(n)}{\delta w_{ji}} \right) \left(\frac{\delta E(n)}{\delta w_{ji}} \right)^T \quad \text{Ec.2.38}$$

Para mayor información de los métodos de inversión de la aproximación de la matriz hessiana (ecuación 28) se puede encontrar en (Dreyfus, G., 2004)³⁷.

2.8. ENTRENAMIENTO DE UNA RED NEURONAL ARTIFICIAL MULTICAPA

Para el proceso de entrenamiento de una red neuronal, es importante recalcar lo que se mencionó en el apartado 2.6.5., el mismo que hace referencia a la necesidad de tener tres subconjuntos de datos que se van a presentar a la red neuronal, que tendrán que estar distribuidos en datos de entrenamiento, de validación y de test y, dependiendo de la regla de aprendizaje se contará con ejemplos de entrada y de salida.

Una vez que se cuenten con los subconjuntos de datos, es importante elegir la topología de la red, el algoritmo de aprendizaje y la función que evaluará el desempeño de la red para evitar problemas de generalización, sobreaprendizaje o mínimos locales, en este caso se proponen los parámetros que serán utilizados para determinar en que punto se debe terminar el aprendizaje y de esta manera garantizar un aprendizaje eficiente y eficaz.

³⁷ Dreyfus, G., "Neural Networks. Methodology and Applications", pág. 193-194, 2004

Con respecto a la arquitectura de las redes neuronales multicapa, el número de capas ocultas dependerá de la complejidad del problema que se desea resolver, por lo general se emplea una sola capa oculta y lo que varía es el número de neuronas ocultas, aunque este último parámetro es definido individualmente y a criterio del autor, debido a que no existen suficientes investigaciones sobre la relación entre el número de neuronas ocultas y la calidad del entrenamiento, solamente existen algunas indicaciones realizadas por diferentes autores³⁸, en este sentido el número de capas y neuronas ocultas dependerán de la complejidad del problema y de los datos que se tengan a disposición.

Es recomendable realizar un tratamiento estadístico previo a los datos de entrada y salida de manera que estén todos dentro de un mismo rango y los valores similares, en el caso de esta investigación se hizo una normalización de los datos, es decir, que los datos sigan una tendencia normal con media cero y desviación estándar de uno.

En lo que se refiere al algoritmo de aprendizaje, se puede emplear el de retropropagación con las diferentes variaciones de los métodos de optimización, lo cual ayudará a la red a converger más rápido, de la misma forma es importante que antes de empezar con cualquier entrenamiento, los pesos sinápticos sean inicializados en cero para que al paso de la señal de activación puedan tomar valores arbitrarios.

Finalmente, se comprueba si el entrenamiento de la red ha dado buenos resultados, para lo cual se emplea el subconjunto de datos de validación para intentar garantizar que la red aprenda patrones extremos y adquiera conocimiento de una complejidad mayor sobre los datos, para que los datos del subconjunto de test demuestren el verdadero error de la red para los 3 subconjuntos como se aprecia en la figura 2.15, donde se observa claramente en la componente vertical como al inicio del entrenamiento se calcula un error alto y conforme va ajustando los pesos sinápticos, el error va disminuyendo hasta alcanzar el error meta propuesta a la red, así como también el mejor punto de convergencia de la red en una determinada época de iteración.

³⁸ Para profundizar a mayor detalle las acotaciones sobre capas y neuronas ocultas se puede observar las siguientes referencias:

- Huang, S.C. & Huang, Y. F., "Bounds on the number of the hidden neurons in multilayer perceptrons", 1991.
- Kung, S. Y. & Hwang, J. N., "An algebraic projection analysis for optimal hidden units size and learning rate in backpropagation algorithm", 1988.

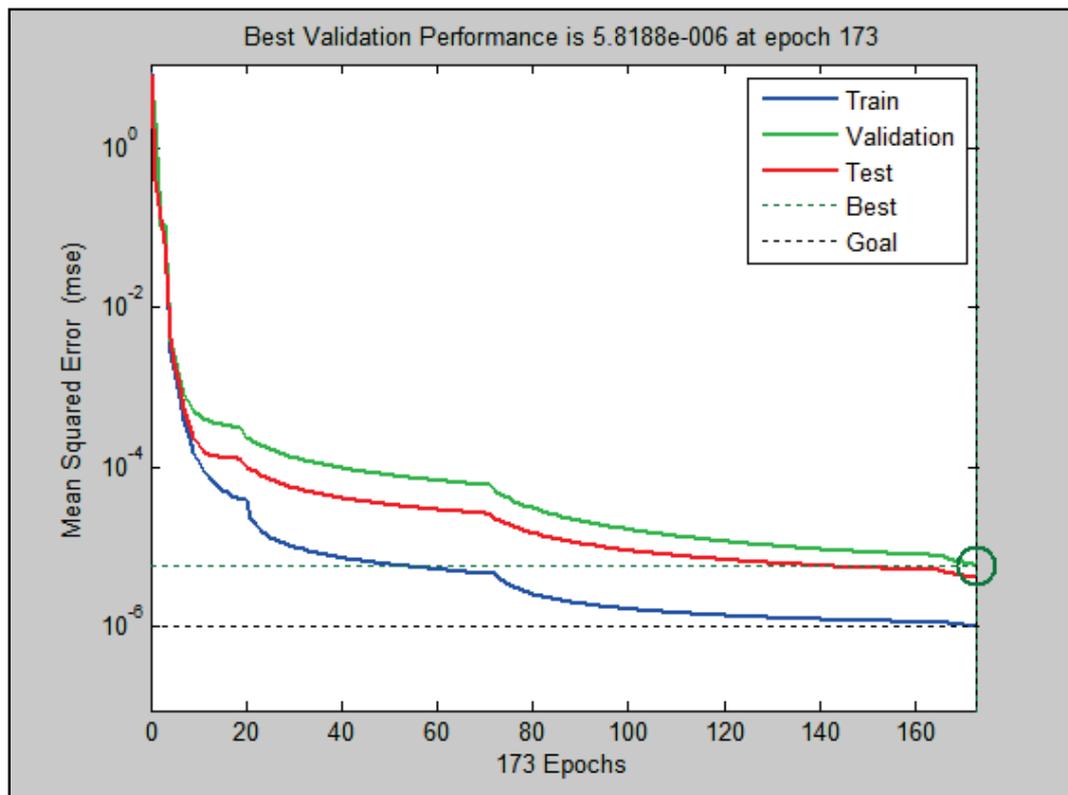


Figura. 2.15. Evolución de las curvas de error para los 3 subconjuntos de datos que se presentan en el entrenamiento de la RNA.

CAPÍTULO 3

METODOLOGÍA

Antes de describir la metodología empleada en este estudio, es preciso recalcar la situación actual de los gobiernos municipales u otras dependencias de gestión territorial que puede aplicar esta metodología en la transformación de coordenadas, la misma que se ha planteado en esta investigación como un escenario próximo a la realidad, en otras palabras se pretende tener lo insumos mínimos que debe contar el usuario para poder desarrollar con normalidad esta técnica, entre estos insumos se puede mencionar los siguientes:

- Cartografía catastral de la zona de trabajo georreferenciada en un sistema topocéntrico y geocéntrico, la misma que servirá para obtener las coordenadas de los puntos de control, de generalización y de comprobación observados en las esquinas de los lotes o puntos que sean fácilmente identificados en la cartografía de ambos sistemas los cuales se le presentará a la red para su posterior cálculo; este proceso se lo puede realizar con un sistema de información geográfica. Este tipo de observación de los puntos se realizó de este modo por el hecho que no existe en todo el territorio nacional los suficientes puntos de control geodésicos o de densificaciones de red georreferenciados en PSAD56 y si los existiera no cuentan con la debida documentación que garantice la exactitud y precisión del punto, por lo tanto, la incertidumbre de la observación del punto en el S.I.G. está estrictamente ligada al acierto de operario.
- Acotando al apartado anterior, se debe tener en cuenta que las coordenadas que se obtendrán en la observación son planas, es decir, son coordenadas que vienen de un cálculo en función de las coordenadas originales, esto es, en el caso de PSAD56 se calculó a partir de coordenadas $A(\varphi, \lambda)$, mientras que en el caso de SIRGAS

proviene de coordenadas $A(X,Y,Z)$, por lo tanto la transformación que se realiza debe ser entre coordenadas proyectadas (Este-Norte).

- En caso de no contar con el catastro en formato digital y solamente se cuente con los planos análogos o físicos, es aconsejable acudir a escáner de alta resolución para que no distorsionen la figura real de las hojas catastrales con el fin de conservar las especificaciones técnicas con las que fueron elaboradas, así como también favorecerá en mantener los niveles de precisión en el proceso de digitalización de lotes, predios y detalles del catastro físico inmobiliario.
- Finalmente, para lograr la transformación es necesario contar con el paquete informático donde se ejecutará el programa de transformación con la técnica de redes neuronales artificiales, y que se ajuste a las necesidades de los diferentes usuarios, en este caso se empleó el software MATLAB.

3.1 AJUSTE DE OBSERVACIONES CON EL MÉTODO DE MÍNIMOS CUADRADOS

El procedimiento previo que se recomienda realizar para seleccionar los puntos que se presentarán en el entrenamiento de la red, es precisamente el ajuste de mínimos cuadrados con el método paramétrico, para lo cual se utilizará el condicionamiento propuesto en la ecuación 2.4, la misma que servirá para calcular los parámetros de transformación que serán aplicados para conocer la consistencia del ajuste, esto se realizará sin variar la verdadera forma de la cartografía original, lo cual es una ventaja muy importante en catastros debido a que los cálculos de impuestos prediales, delimitación de propiedades y solución de conflictos de tierras en general, no tendrán variaciones significantes.

Los requerimientos para resolver el ajuste con esta metodología es determinar por lo menos tres puntos de control para establecer un sistema de 6 ecuaciones y 4 incógnitas dando mejor confianza en los grados de libertad para el ajuste. En este estudio se emplearon cuatro puntos que se ubican en los extremos del área total de estudio cubriendo

con la condición que todo el territorio entre en el ajuste, como se puede ver en la figura 3.1.



Figura. 3.1. Puntos seleccionados para el ajuste de mínimos cuadrados observados tanto en la cartografía de PSAD56 como en SIRGAS00

Las coordenadas de los puntos que se observan en la figura anterior, también están detalladas en la siguiente tabla.

Tabla. 3.1. Coordenadas de los puntos utilizados para calcular los parámetros de transformación por el método de mínimos cuadrados.

Coordenadas TMQ-PSAD56		Coordenadas TMQ-SIRGAS00	
ESTE(m)	NORTE(m)	ESTE(m)	NORTE(m)
501500	9982800	501263.33950	9982432.49230
503900	9982800	503663.31390	9982432.49430
503900	9981600	503663.30840	9981232.50100
501500	9981600	501263.33400	9981232.49880

Con los parámetros de transformación que se obtienen como resultado del ajuste, se procede a transformar espacialmente la cartografía digital, para lograr esto se recurrió al

módulo de transformación espacial que se puede encontrar en sistemas de información geográfica como gvSIG, SAGA GIS, Kosmo, entre otros, los mismos que ayudan al operario a visualizar la cartografía catastral transformada con los niveles de precisión que otorgan los parámetros de transformación, los mismos que son presentados y analizados en el apartado 4.1 del presente documento.

3.2 SELECCIÓN DE PUNTOS PARA EL ENTRENAMIENTO DE LA RED NEURONAL ARTIFICIAL

Como se explicó en el capítulo anterior, los puntos que se deben tomar en consideración para el entrenamiento de la red deben estar clasificados en 3 subconjuntos, tanto para las entradas como para las salidas, los cuales fueron observados en la cartografía catastral digital del Distrito Metropolitano de Quito en el sector de Iñaquito referenciado en PSAD56 y SIRGAS00³⁹, con una extensión de territorio aproximada de 212 hectáreas, la cantidad de puntos observados en el SIG fueron un total de 60 puntos distribuidos en los tres subconjuntos, los mismos que están distribuidos en la zona de estudio como se observa en la figura 3.2.

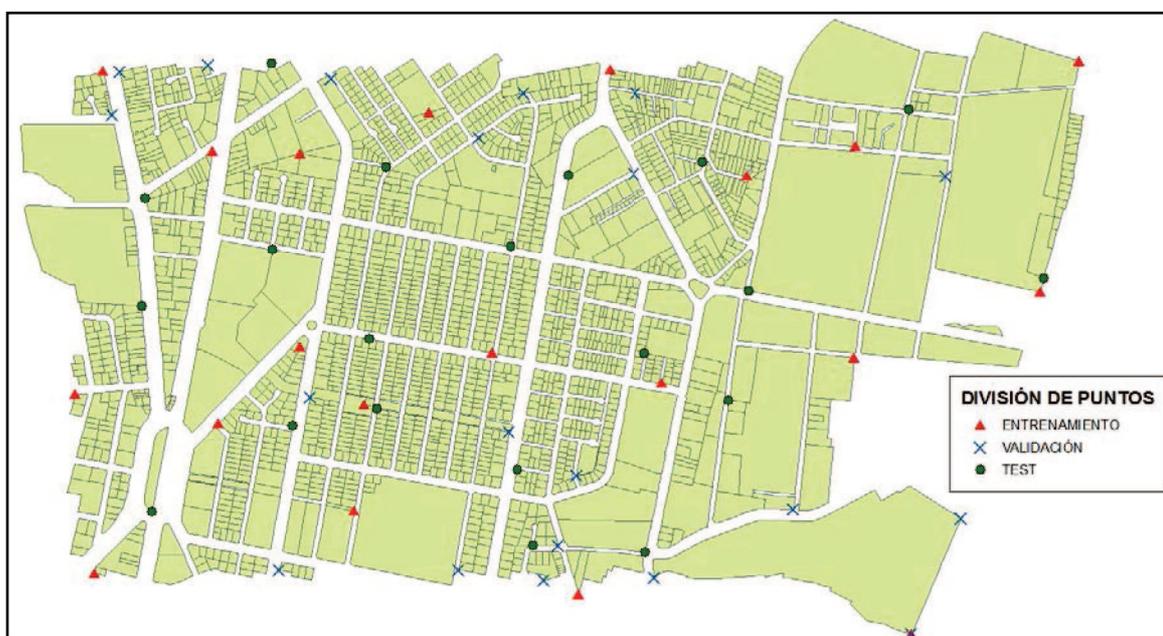


Figura. 3.2. Distribución de los puntos seleccionados para el entrenamiento y aprendizaje de la RNA

³⁹ La información a la que se hace alusión fue proporcionada por la Dirección Metropolitana de Catastro del D.M. de Quito, 2011.

El criterio que se empleó en la selección de los puntos de entrenamiento o de control que se emplearon en la fase de entrenamiento de la RNA multicapa es básicamente utilizar puntos fácilmente identificables en ambos sistemas, además que cubran la totalidad del territorio y que su distribución siga una tendencia sinusoidal, en este caso se observaron las coordenadas de 20 puntos, las mismas que se encuentran adscritas en el anexo 2.

Para determinar los puntos de validación en este estudio, se realizó el ajuste de mínimos cuadrados con el método paramétrico, en donde fue necesario utilizar las coordenadas los puntos de que se presentaron en la tabla 3.1 que cubrían la totalidad de la superficie, de esta manera se calcularon los parámetros de transformación que al ser utilizados en el SIG para la transformación espacial, sirvieron para conocer las zonas donde se evidenciaban eventos extremos de las coordenadas, por lo tanto fueron puntos que se observaron en zonas donde las diferencias entre los valores calculados y observados fueron mínimas o casi insignificantes y también donde se presentaron mayores distorsiones, las coordenadas de estos puntos también están agregadas en el anexo 2.

Finalmente los puntos test o de comprobación no siguen una regla o especificación técnica en particular, simplemente se recomienda que sean puntos distribuidos aleatoriamente en todo el territorio y que no estén considerados en los anteriores subconjuntos de datos. Según (Najah, A. et al, 2012) el subconjunto de datos de comprobación podría estar comprendido aproximadamente entre el 10-40% del total de los datos que serán presentados a la red⁴⁰, es así que se observaron 20 puntos en la zona de Iñaquito y sus coordenadas, al igual que los puntos anteriores, también están en el anexo 2. Con todo esto se puede dar un enfoque general para un buen entrenamiento de la red.

3.3. PRE-PROCESAMIENTO Y POST-PROCESAMIENTO ESTADÍSTICO DE LOS DATOS

Este paso se realizó para mejorar el rendimiento de la RNA normando los datos para estar en un rango determinado de valores, por citar un ejemplo, si los valores en las neuronas de entrada son muy grandes, entonces los valores de los pesos sinápticos y del umbral serán demasiados pequeños para evitar que el campo inducido que ingresa a la

⁴⁰ Najah, A., El-Sahfie, A., Karim, O. & El-Sahfie H., "Application of Artificial Neural Network for water quality prediction", 2012.

función de transferencia se sature, si esto sucede en el inicio del entrenamiento de la red, los gradientes serán demasiados pequeños dando como consecuencia un entrenamiento lento⁴¹.

En este estudio se empleó la normalización de los datos con media igual a cero y con desviación estándar de uno en ambos conjuntos de datos, tanto de entrada y de salida deseada, de esta manera se asegura que la respuesta de la RNA también esté comprendida en un rango normalizado. Posteriormente se desnormaliza la salida calculada por la red para calcular las diferencias en unidades de origen.

3.4. SELECCIÓN DE LA ARQUITECTURA DE LA R.N.A.

La arquitectura de la red que se empleó en este problema de transformación de coordenadas, fue una red neuronal multicapa con una capa oculta y su posterior capa de salida, mientras que la topología empleada para la conexión de las neuronas fue de flujo unidireccional con el algoritmo de aprendizaje supervisado de retropropagación empleando la optimización numérica de Levenberg-Marquardt, siguiendo los criterios, fórmulas y consideraciones que se explicaron en el capítulo anterior.

En la figura 3.3 se observa la topología empleada en este trabajo donde se aprecia que la capa de entrada se encuentra compuesta por 2 vectores de entrada correspondientes a las coordenadas Este y Norte del sistema PSAD56 de cada punto, las mismas que fueron procesadas en la capa oculta con 6 neuronas artificiales donde será aplicada la función de activación sigmoidea tangente hiperbólica y, la respuesta de la señal de activación de esta capa oculta pasará por una función de transferencia lineal que originará como respuesta dos salidas, las cuales serán precisamente las coordenadas Este y Norte de los mismos puntos pero ya calculados en el sistema SIRGAS00; es aquí donde se presentan los datos de salida deseados para que la red calcule el error y, mediante el algoritmo de retropropagación ajuste todos los parámetros libres de la red hasta que la respuesta de la red se aproxime en el error mínimo y por consiguiente conocer si el aprendizaje es exitoso.

⁴¹ Hudson, M., et al, "Neural Network Toolbox, Guía de usuario", 2012.

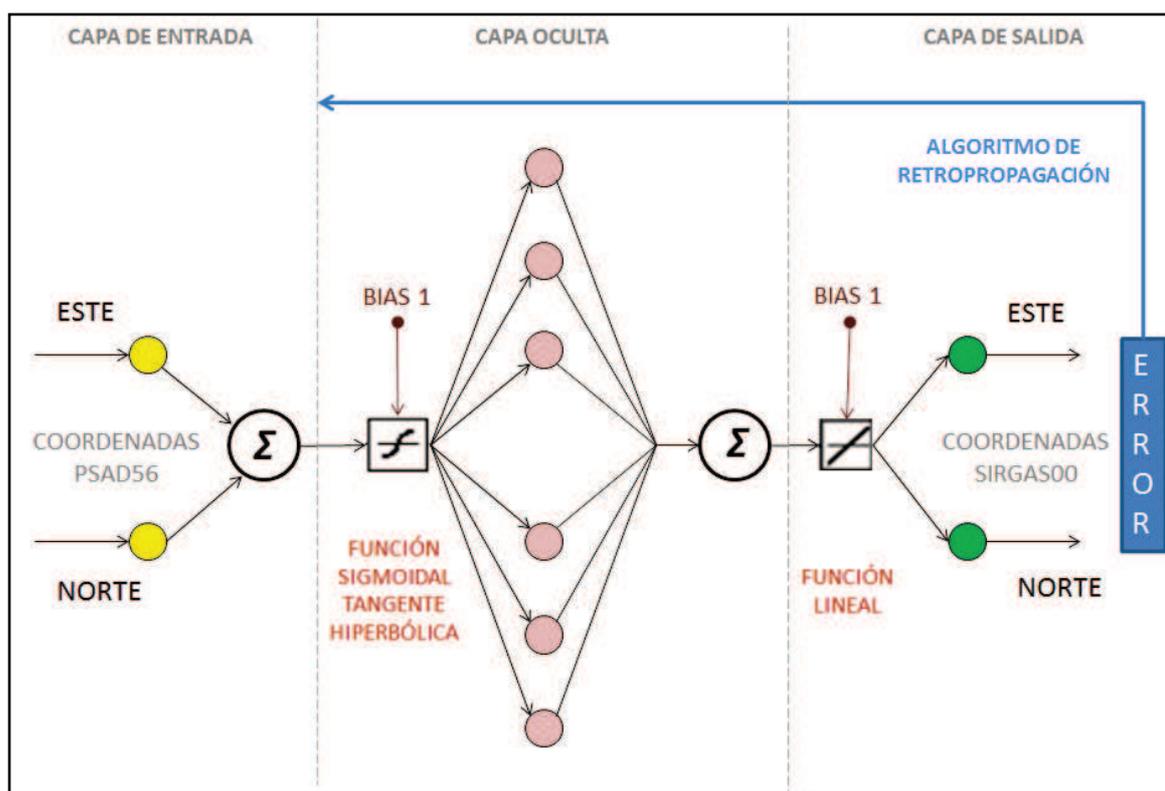


Figura. 3.3. Topología de la RNA usada en el presente trabajo.

3.5. ENTRENAMIENTO DE LA RED NEURONAL ARTIFICIAL

El entrenamiento de la red neuronal artificial debe asegurar que las discrepancias entre los valores de salida de la RNA y los valores deseados sean lo mínimo posible, en este caso y para la presente investigación, la diferencia en la posición sea menor a 1.5 metros para que de esta manera sea compatible con escalas mayores a 1:5 000.

Es precisamente en este apartado en el cual se aplica el entrenamiento de la RNA con el algoritmo de aprendizaje y su optimización numérica, para lo cual fue necesario diseñar el programa en el software de MATLAB que sea flexible para cambiar datos o parámetros de entrenamiento, además que cumpla con las condiciones de eficiencia del rendimiento y buen aprendizaje. La metodología del entrenamiento de la RNA que se ilustra en la figura 3.4, es un proceso de selección de constantes ensayos y modificaciones de número de neuronas ocultas, períodos de iteración, error meta que se desea alcanzar, tiempo de entrenamiento, entre otros, hasta encontrar una arquitectura de red y estructura del programa que más se acerque a cumplir con el objetivo principal.

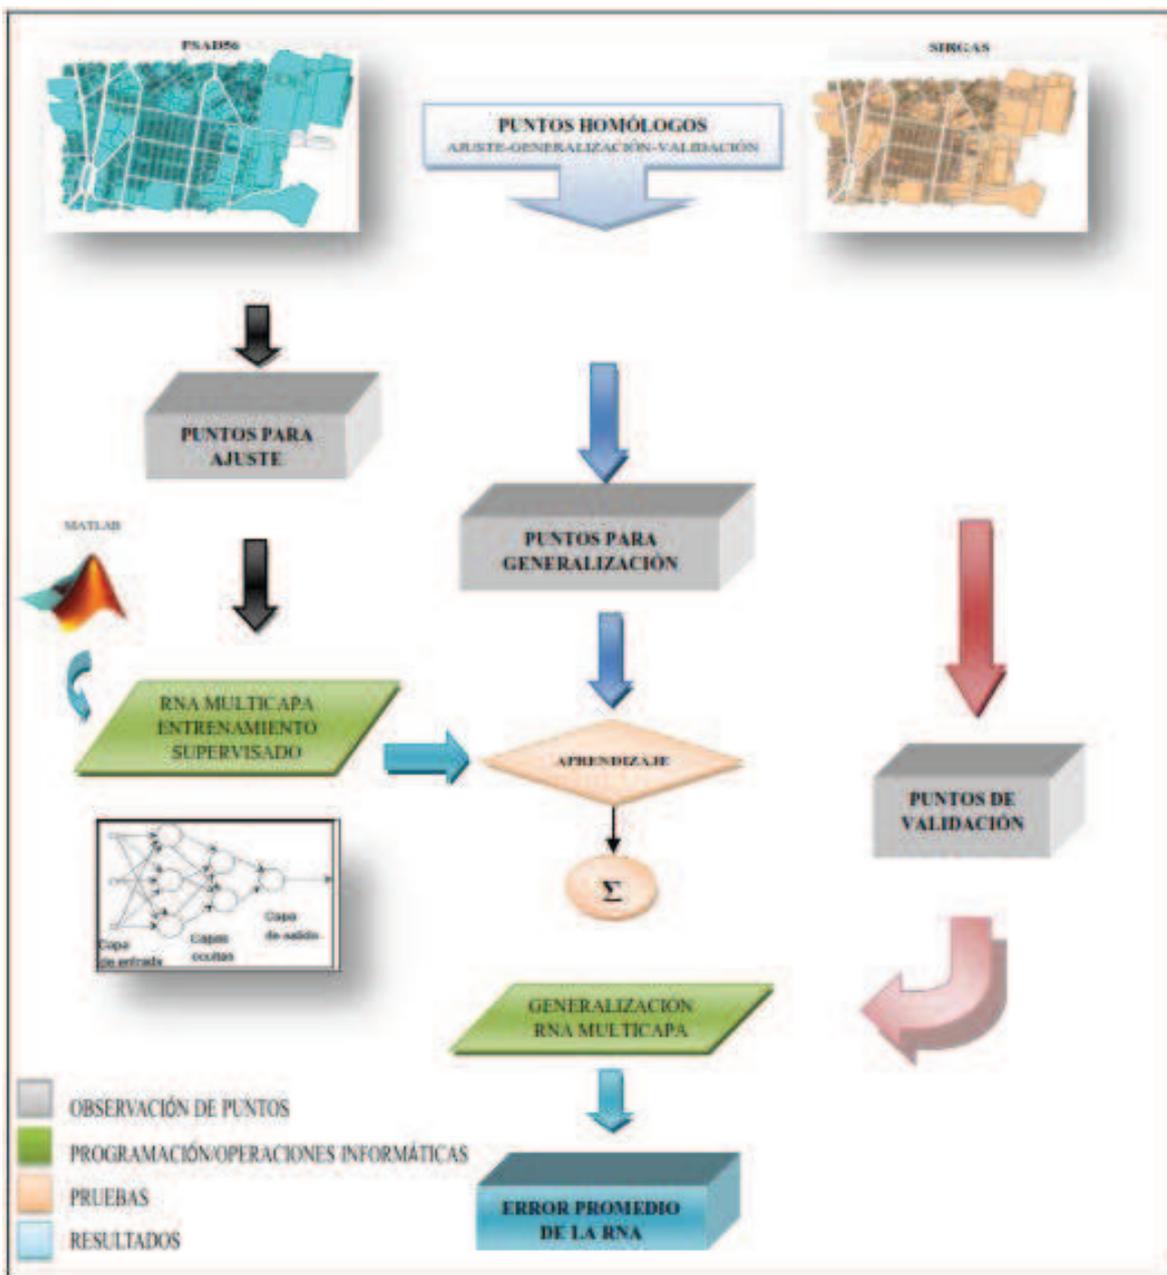


Figura. 3.4. Proceso para desarrollar la metodología del entrenamiento de la RNA en la transformación de coordenadas.

Se puede observar que los conjuntos de entrada y de salida deseada se realizan fuera del programa de MATLAB, se puede valer de un sistema de información geográfica libre o comercial. Los conjuntos de datos que se emplearon en el entrenamiento se detallan en el anexo 2.

En el diseño del programa de la transformación se utilizó la herramienta de redes neuronales artificiales (*Neural Network Toolbox*), donde se pudo configurar los parámetros de entrenamiento de la red, por ejemplo:

- El pre-procesamiento estadístico de los datos para la normalización con media cero y varianza 1 se utilizó la función '**mapstd**' que crea dos repositorios, el primero que contiene los datos normalizados y el segundo comprende con la configuración del proceso de normalización que permite retomar los valores originales de los datos. En este mismo proceso es conveniente indicar que al final del entrenamiento es necesario conocer los resultados del aprendizaje con los valores y unidades originales, para lo cual se emplea la función '**reverse**', la misma que se basa del segundo repositorio creado en el pre-procesamiento para generar la salida con las coordenadas Este-Norte.
- El siguiente paso es crear la RNA, para lo cual se emplea la función '**net**' que requiere conocer la topología y el algoritmo de entrenamiento, en este caso se empleó la función '**newff**'⁴², la cual al ser activada, implícita y automáticamente se configura para que utilice el algoritmo de retropropagación con la optimización de Levenberg – Marquardt, adicional a esto se suma que por defecto la red está compuesta por una capa de neuronas ocultas y una capa de salida.
Esta función necesita conocer principalmente, el conjunto de entrada y de salida, además del número de neuronas ocultas.
- Cabe recalcar que los conjuntos de entrada y salida están conjuntamente los datos de entrenamiento, validación y test, pero para que la RNA pueda diferenciarlos se emplea la función '**divideind**', que tiene la capacidad de dividir el conjunto de datos en bloques, es así que el primer bloque de 20 datos serán destinados al entrenamiento, mientras que el siguiente bloque de 20 datos serán para ayudar a la generalización de la red y finalmente el tercer bloque de 20 datos servirán para comprobar el aprendizaje de la red.

⁴² New Feed Forward network = red unidireccional

- Previo al proceso de entrenamiento de la red, es recomendable modificar los parámetros del entrenamiento para determinar hasta que punto se puede detener el aprendizaje, por tal razón se tomaron en cuenta los valores que se detallan en la tabla 3.2.

Tabla. 3.2. Valores de los parámetros para detener el entrenamiento de la RNA

Función	Descripción	Valor
net.trainParam.epochs	Número máximo de épocas de iteración del entrenamiento	500
net.trainParam.goal	Rendimiento que se desea alcanzar	1E ⁻⁷
net.trainParam.show	Número de épocas que serán desplegadas	20
net.trainParam.time	Máximo tiempo de entrenamiento en segundo	inf

Nota: Los parámetros restantes se mantienen con los valores que se generan por defecto, estos pueden ser revisados en las guías de usuario de MATLAB.

- El siguiente paso es la inicialización de los pesos sinápticos con valores cercanos a cero para que al paso de la señal de activación tomen valores aleatorios, para este caso se empleó la función **'init'**.
- Luego de esto se puede iniciar el entrenamiento de la red con la función **'train'**, la cual pide como requisitos presentar la red que se creó (unidireccional), las entradas y las salidas deseadas y se detendrá cuando se cumpla alguno de los parámetros especificados en la tabla 3.2. Para determinar si la red ha respondido correctamente, se puede simular la red con la función **'sim'**. Esta función también se puede emplear antes de iniciar con el entrenamiento cuando se le presentan los conjuntos de entrada y salida, para que la red intente simular los resultados.
- Finalmente se recomienda ilustrar con los gráficos del entrenamiento los procesos de rendimiento y simulación para un mejor análisis de revisión del entrenamiento.

Para mejor conocimiento de este proceso de diseño del programa de transformación de coordenadas, se puede recurrir al anexo 3 de este trabajo, donde se encuentra detallado los pasos de programación con su respectiva justificación.

3.6. MAPA DE DISTORSIONES

Este mapa de distorsiones sirve para conocer las zonas del área de estudio donde se evidenciaron diferencias significativas después del cálculo de transformar las coordenadas, además para determinar el porcentaje de datos que cumplen con los requerimientos del objetivo principal (diferencia menor a 1.5m) con lo cual se consigue determinar la fiabilidad de la metodología.

El insumo determinante para obtener las diferencia de los datos son las gráficas de error que se obtiene para cada una de las coordenadas, es decir, tanto para las diferencias en las coordenadas Este como en las de Norte, y finalmente se calcula el error en posición con lo cual se obtienen las magnitudes del error de cada punto. La ilustración del mapa de distorsiones de la transformación de coordenadas con la RNA se aprecia en el anexo 4.

CAPÍTULO 4

DISCUSIÓN DE LOS RESULTADOS

4.1. ANÁLISIS DE LOS RESULTADOS OBTENIDOS EN EL AJUSTE CON MÍNIMOS CUADRADOS

Como se explicó en el capítulo anterior, el procedimiento previo al entrenamiento de la red neuronal artificial, es el ajuste con el método paramétrico de mínimos cuadrados para el cálculo de parámetros de transformación y de esta manera establecer las zonas de menor y mayor distorsión. El resultado en este paso son cuatro parámetros de transformación que se detallan en la tabla 4.1.

Tabla. 4.1. Parámetros de transformación calculados con mínimos cuadrados

Parámetro	Valor
Traslación Este	-234 m
Traslación Norte	-271.23 m
Ángulo de Rotación	2.17 E^{-7} rad
Diferencial de escala	-9.63 E^{-6}

Con estos valores se transformó espacialmente la zona de estudio con la ayuda del software gvSIG, en su módulo “Sextante” en la opción “Transformar” donde se evidenciaron con distorsiones pequeñas que no sobrepasaban los 0.30 metros de diferencia, así como también las zonas con grandes distorsiones que sobrepasan los niveles de precisión requeridos, es decir, eran mayores a 1.5 metros de diferencia. Para ilustrar de mejor manera estas zonas que representan eventos extremos en cuanto se refiere a diferencia, se presenta la figura 4.1 en donde se observa en tono verde la zona con distorsiones pequeñas, en tono rojo la zona con mayores distorsiones y finalmente el resto del territorio que fluctúan diferencia entre 0.30 y 1.5 metros.



Figura. 4.1. Determinación de zonas con eventos extremos de distorsión en la zona de estudio utilizando el ajuste con mínimos cuadrados

Con los valores de los parámetros de transformación se procedió a calcular las coordenadas en el sistema SIRGAS utilizando los puntos observados que se detallan en el anexo 2, a fin de poder comparar los mismos resultados con los calculados por la RNA, los valores obtenidos en la precisión de la posición empleando parámetros de transformación se detallan en la tabla 4.2.

Tabla. 4.2. Resultados obtenidos en la transformación de coordenadas utilizando parámetros de transformación

VARIABLE	VALOR
Media aritmética	0.845 m.
Desviación estándar	1.335 m.
Error mínimo	0.004 m.
Error máximo	3.301 m.
Número de datos con valores superiores o iguales a 1.5 m	17
Porcentaje válido de los datos	71.67%
Coefficiente de variación	1.54

Nota: Si se desea verificar los valores de la tabla 4.2 se puede revisar el anexo 5 que contiene los resultados de las diferencias entre las coordenadas SIRGAS calculadas y observadas.

Como se pudo observar en la tabla 4.2, los resultados obtenidos utilizando parámetros de transformación se evidencia una cantidad considerable de datos que sobrepasan el umbral de 1.5 m, por lo que genera en más sectores de la zona de estudio distorsiones grandes, en la figura 4.2 se observa como los parámetros de transformación originan fuertes picos de distorsión, así como también valles pronunciados con diferencias despreciables, es decir, no existe una homogeneidad en los valores.

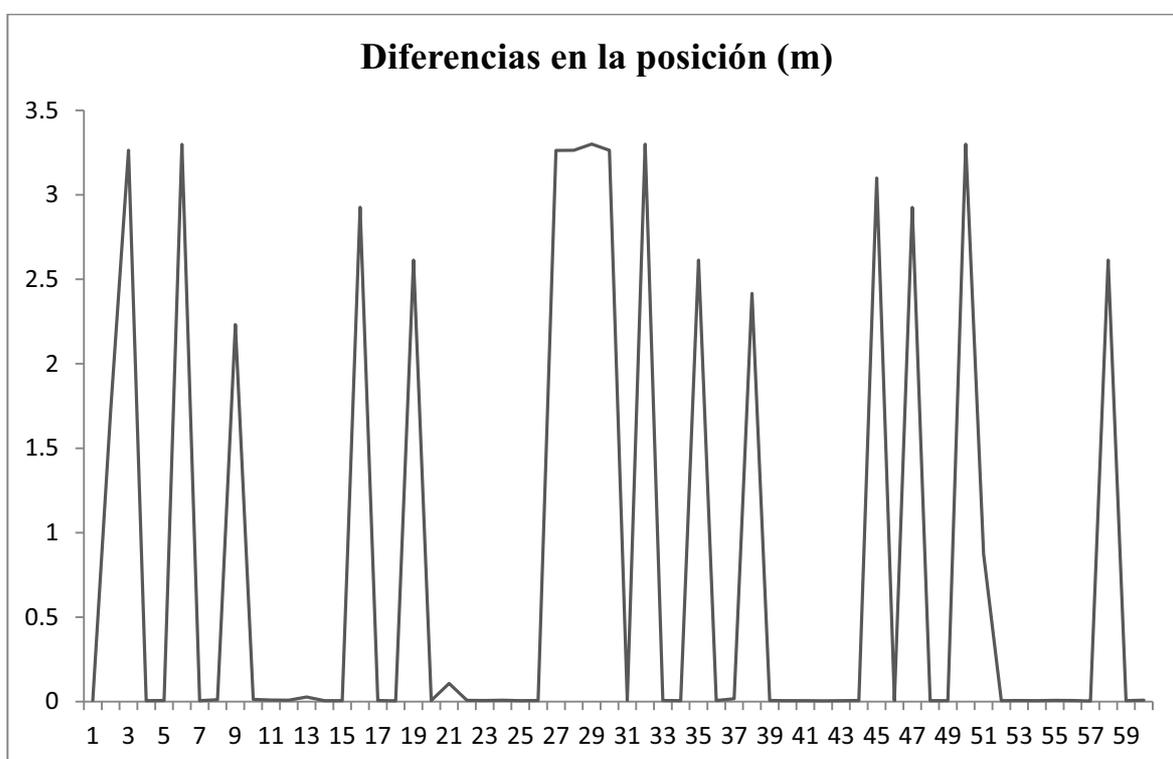


Figura. 4.2. Distorsiones generadas en la posición de los 60 datos utilizando parámetros de transformación

4.2. ANÁLISIS DE LOS RESULTADOS OBTENIDOS CON UNA RED NEURONAL ARTIFICIAL MULTICAPA

Posteriormente se realizó el cálculo de las coordenadas con la metodología de RNAM, para lo cual, se procedió a presentar los datos a la red para que esta sea capaz de

simular los valores de salida como paso previo al entrenamiento, en donde se produjo el ajuste que se aprecia en la figura 4.3.

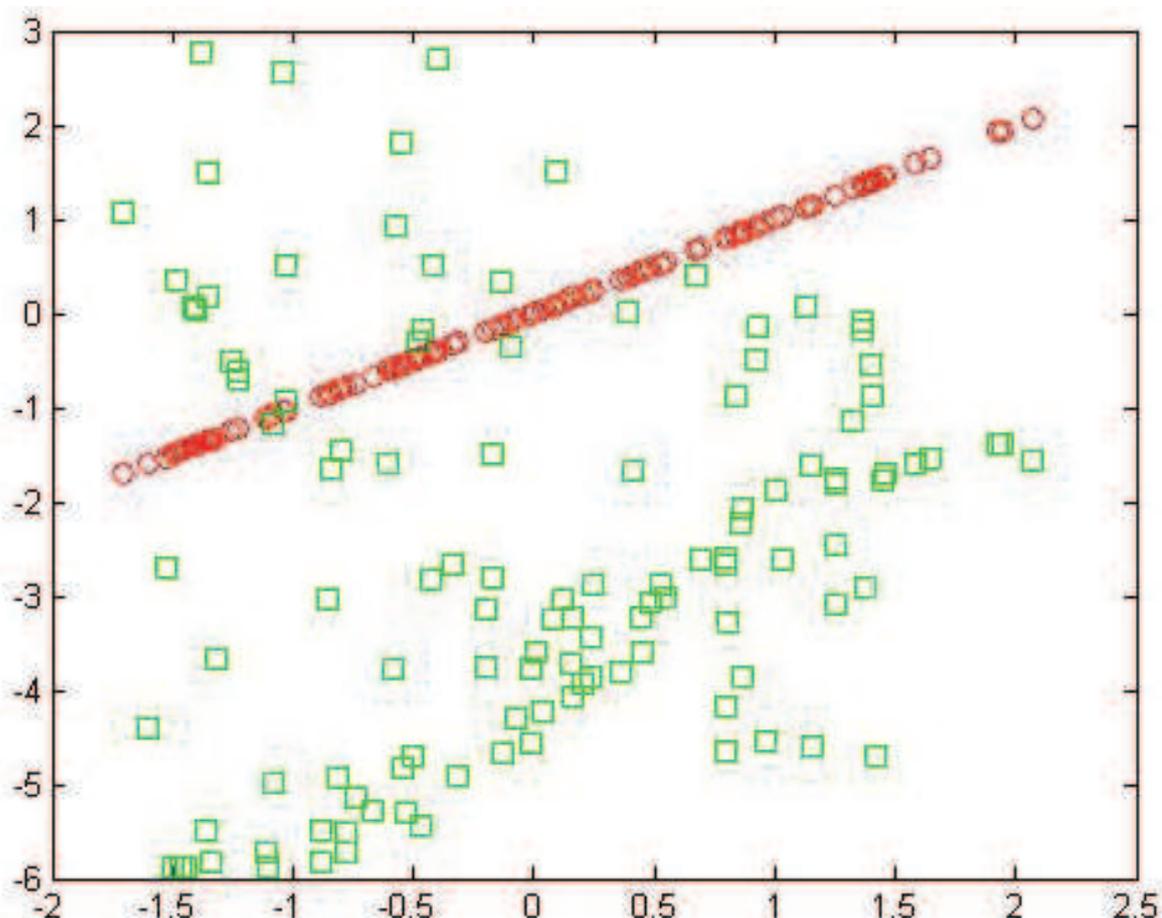


Figura. 4.3. Ajuste de los datos de las coordenadas en la simulación de la RNAM

De la figura anterior se observa en el eje horizontal las coordenadas normalizadas en PSAD56, mientras que en el eje vertical se observa las coordenadas normalizadas en SIRGAS00. La secuencia de datos en color rojo muestra la respuesta deseada de la red y como debería ser el ajuste de los datos, mientras que por otro lado, los datos que se encuentran dispersos en el área del gráfico son la simulación de la red apenas son presentados los datos a la red.

Posteriormente se realizó el entrenamiento de la RNAM con los parámetros de entrenamiento que se expusieron en la tabla 3.1 del capítulo anterior, en donde se observó que el proceso de entrenamiento ajustó los datos calculados a los esperados con

discrepancias mucho menores a las presentadas en el figura anterior, por lo tanto en la figura 4.4 se observa el ajuste de las coordenada calculadas a las observadas.

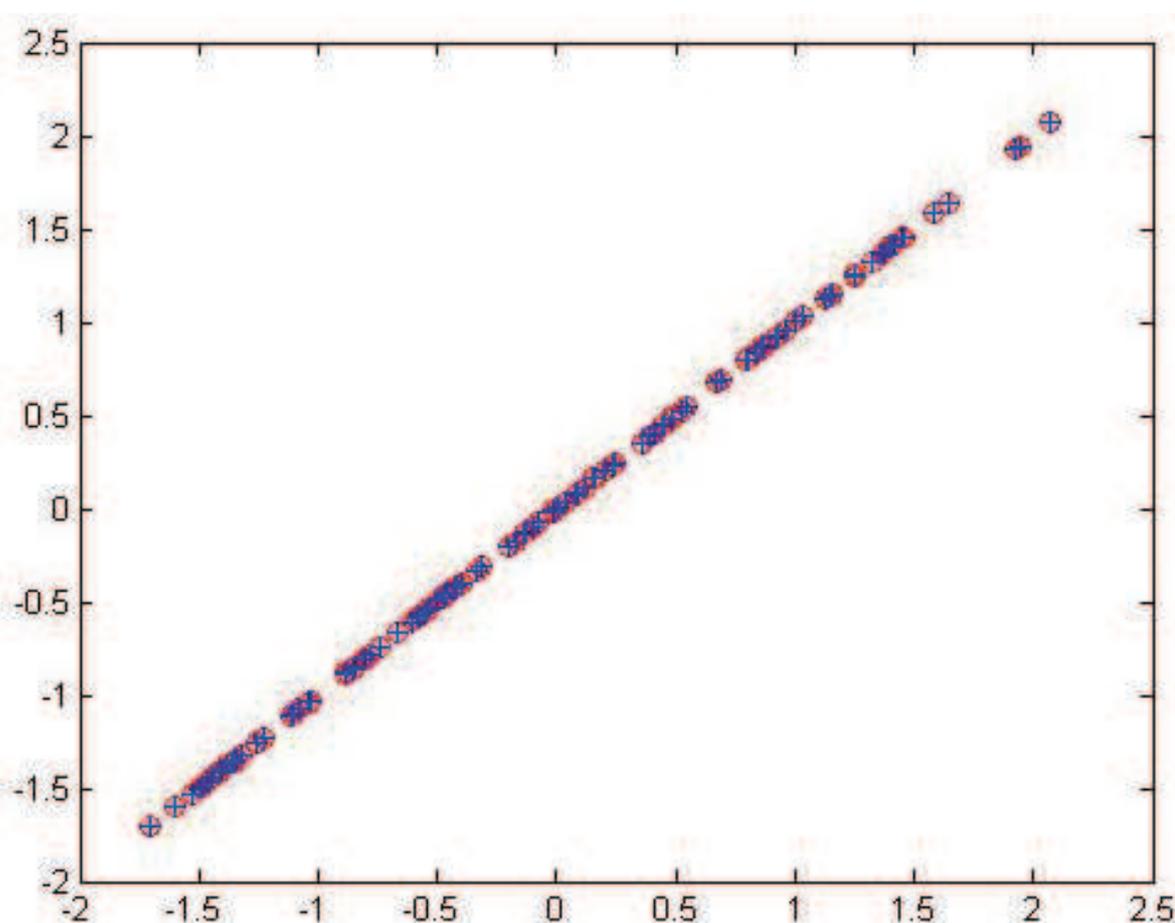


Figura. 4.4. Ajuste de los datos de las coordenadas después del entrenamiento de la RNAM

En la figura 4.4, se observa cómo los valores de las coordenadas calculadas, representadas con la secuencia de datos en color azul, se ajusta a los datos de salida esperados representados por la secuencia de datos de color rojo, dando un pronóstico favorable y alentador al cálculo de las diferencias entre coordenadas calculadas y observadas, obviamente estos resultados se verán después que pasen el proceso de desnormalización.

Una vez que se han cumplido todos los pasos del proceso de entrenamiento, se procede a la desnormalización de los resultados como se expuso anteriormente, en donde se conoce los valores calculados por la red pero con las unidades y valores de interés, en donde se procede a verificar las diferencias resultantes entre las coordenadas Este y Norte. En la figura 4.5 y 4.6 se observa estas diferencias en unidades métricas tanto para las

coordenadas en Este como para las coordenadas en Norte, respectivamente. En el eje vertical están representadas las diferencias en metros, mientras que en el eje horizontal están los datos que se utilizaron para el entrenamiento, validación y test.

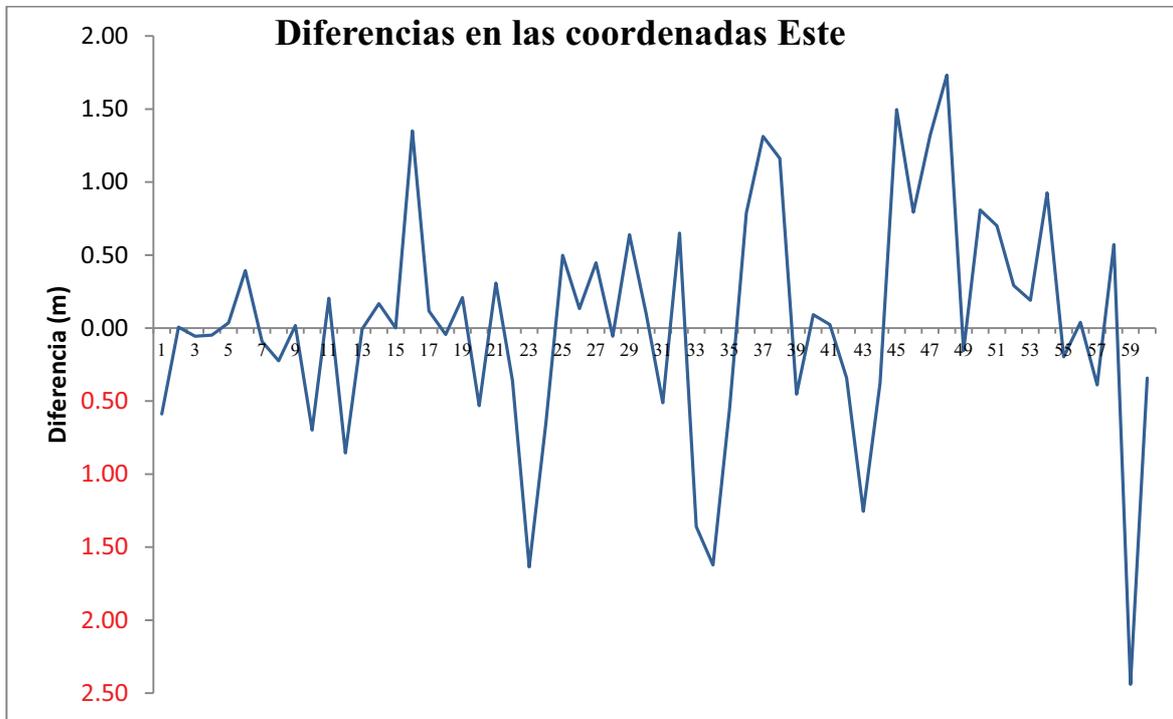


Figura. 4.5. Diferencia (m) de los valores en coordenadas Este para los 60 puntos observados

Se puede apreciar en la figura anterior que los valores fluctúan entre los picos de -2.43 m y 1.73 m con una desviación estándar de 0.77 m, en donde solamente 5 datos quedan fueran del rango establecido de precisión que es menor a una diferencia de 1.5m, a pesar de que existen picos y valles en los valores, estos no sobrepasan la precisión que se espera. Para complementar la información presentada, también se expone la siguiente figura con la información de las coordenadas en norte.

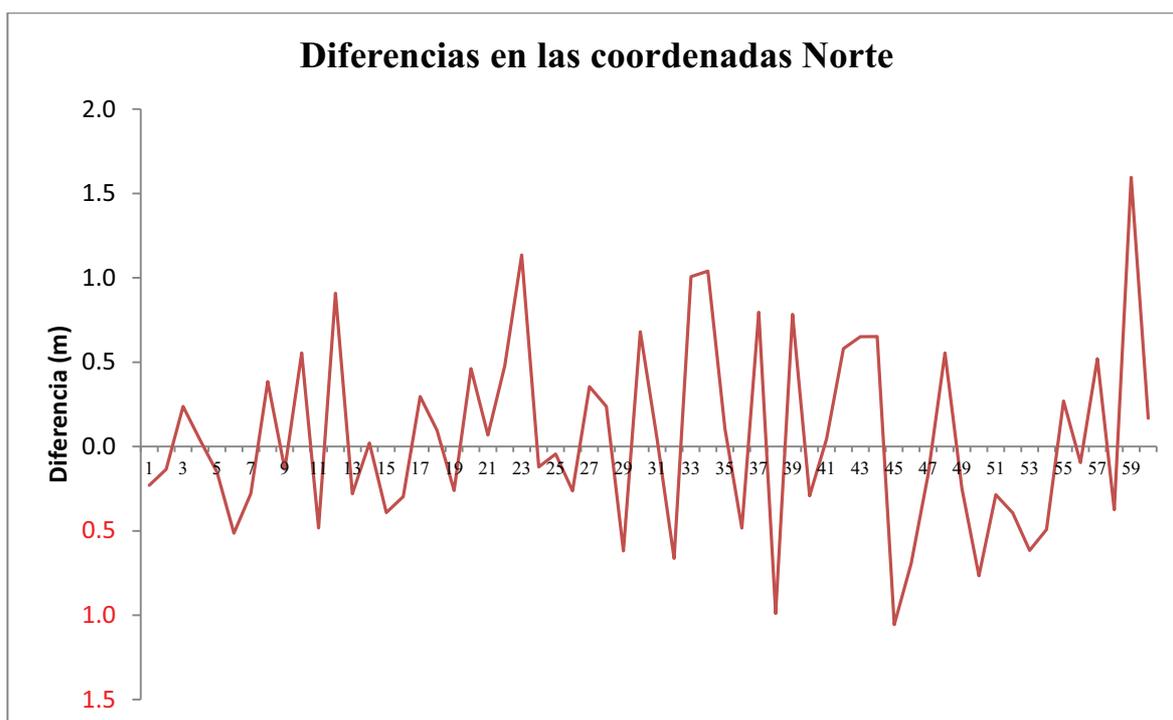


Figura. 4.6. Diferencia (m) de los valores en coordenadas Norte para los 60 puntos observados

En la figura 4.6 se aprecia como las diferencias en las coordenadas Norte varían desde los picos -1.05 m hasta 1.59 m, con una desviación estándar de 0.55 m, en donde sobresale solamente un dato que queda fuera del rango permitido de precisión. Con los valores de las diferencias en las coordenadas este y norte se procede a calcular el error total en la posición horizontal, el cual determinará la calidad de la metodología, para lo cual se presenta en la tabla 4.3 las estadísticas generales de los resultados finales de las diferencias en la posición horizontal.

Tabla 4.3. Resultados obtenidos en la transformación de coordenadas utilizando una RNAM

CARACTERÍSTICA	VALOR
Media aritmética	0.750 m.
Desviación estándar	0.585 m.
Error mínimo	0.050 m.
Error máximo	2.915 m.
Número de datos con valores superiores o iguales a 1.5 m	8
Porcentaje válido de los datos	86.67%
Coficiente de variación	0.78

Nota: Si se desea revisar los datos que resultaron del cálculo de la red neuronal artificial y sus cálculos para obtener los valores de la tabla 4.3 se puede recurrir al anexo 6 como fuente de verificación.

Como se observa en los valores anteriores, el error promedio en la posición si cumple con los niveles de precisión requeridos para escalas mayores a 1:5 000, incluso con la desviación estándar, este valor no sobrepasa el valor de 1.5 m, además se observa que los valores que superiores a 1.5 m solamente representa el 14% de los datos aproximadamente, es decir, la metodología es aplicable en la mayoría del territorio. En la figura 4.7 se evidencia lo antes citado.

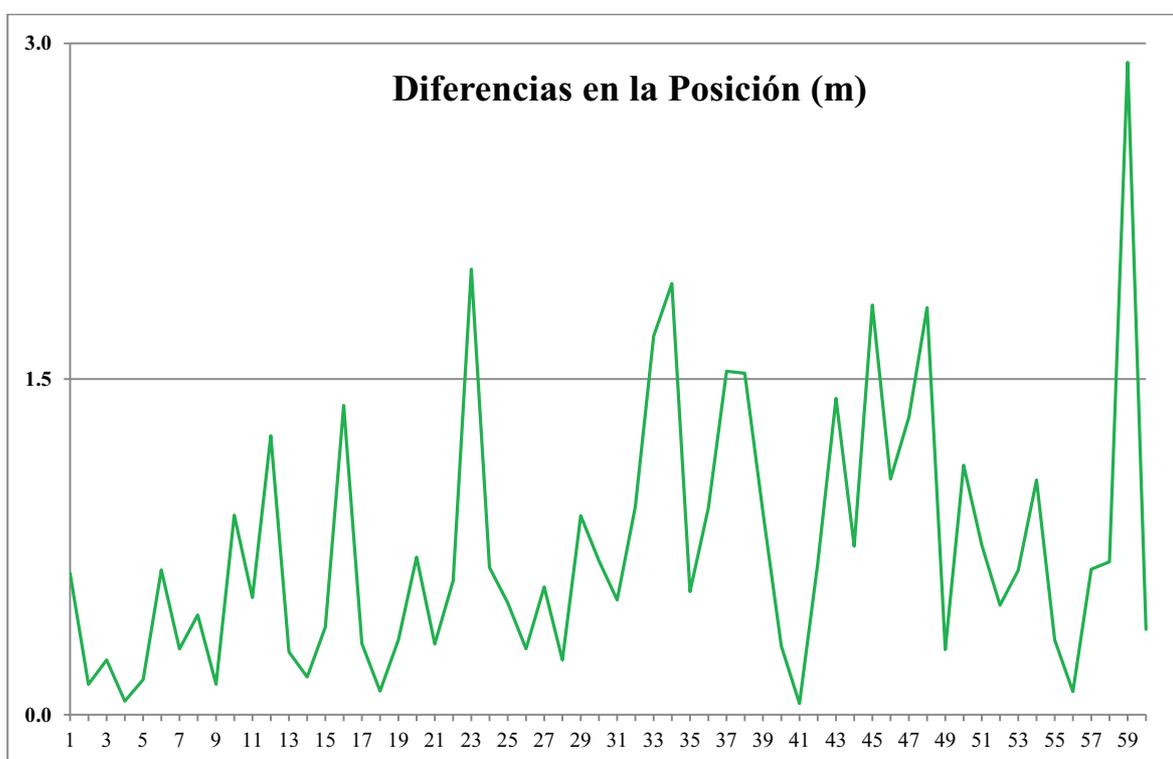


Figura. 4.7. Diferencias (m) de la posición de los 60 datos en estudio

De la figura anterior se exponen las diferencias en metros en el eje vertical mientras que los datos se presentan en el eje horizontal, además se aprecia mayor homogeneidad entre los resultados obtenidos los cuales se encuentran representados en el mapa de distorsiones que se encuentra en el anexo 4. Además se puede complementar que los datos de entrenamiento (1 al 20) no sobrepasan el valor de 1.5 m. Mientras que los datos de validación (21 al 40) que contienen los valores con características extremas, presentan 5

valores que no se ajustan al nivel de precisión y, finalmente los datos test (41 al 60) presentan 3 datos que sobrepasan el valor de 1.5 m. además que aquí se encuentra el dato con diferencia máxima que es de 2.915m.

4.3. COMPARACIÓN ENTRE LOS RESULTADOS OBTENIDOS CON PARÁMETROS DE TRANSFORMACIÓN Y UNA RNAM

En este apartado se pretende comparar ambas metodologías para demostrar la fiabilidad y efectividad de las técnicas empleadas, a fin de dar un enfoque técnico a la solución de transformación de coordenadas, para tener un sustento práctico en la decisión de optar por un método estadístico convencional como es el ajuste de mínimos cuadrados o una técnica no convencional de predicción de resultados como es las redes neuronales artificiales.

En resumen se puede decir que la metodología de redes neuronales artificiales puede reducir las diferencias en la posición de manera más eficiente que los parámetros de transformación, la tabla 4.4 representa una compilación de los resultados obtenidos con ambas técnicas.

Tabla. 4.4. Cuadro resumen de los resultados obtenidos con Parámetros de Transformación y una Red Neuronal Artificial

Variable	Resultados obtenidos con parámetros de transformación	Resultados obtenidos con una RNAM
	Valor	Valor
Media aritmética	0.845 m	0.750 m
Desviación estándar	1.335 m	0.585 m
Error mínimo	0.004 m	0.050 m
Error máximo	3.301 m	2.915 m
Amplitud entre el valor mínimo y máximo	3.297 m	2.865 m
Número de datos con valores superiores o iguales a 1.5 m	17	8
Porcentaje válido de los datos	71.67%	86.67%

Coeficiente de variación	1.54	0.78
--------------------------	------	------

Se aprecia claramente que los resultados producidos por la red neuronal artificial mejoran los valores obtenidos por los parámetros de transformación, favoreciendo esta metodología para aplicar en la transformación de coordenadas la misma que tiene mayor porcentaje de aplicabilidad (86.67%) en el territorio en estudio y con menor rango entre las discrepancias mayores y menores (2.865 m), permitiendo que sea compatible con escalas mayores a 1:5 000 con mejor homogeneidad en los valores calculados, y así siendo aplicable a cartografía catastral rural y ciertos proyectos del catastro urbano que requiera precisión promedio de 0.75 m.

CAPÍTULO 5

CONCLUSIONES Y RECOMENDACIONES

5.1. CONCLUSIONES

- La transformación de coordenadas planas o proyectadas (Este, Norte) ha dado mejores resultados que los presentados en los antecedentes de la transformación empleando coordenadas cartesianas (X, Y, Z).
- El uso de la técnica de redes neuronales artificiales, en este caso una red multicapa y unidireccional, empleada en la transformación de coordenadas planas para migrar la cartografía de un sistema topocéntrico a uno geocéntrico, resultó compatible con escalas menores a 1: 2500, las mismas que servirán para proyectos de catastros que requieran precisiones decimétricas.
- En el cálculo de parámetros transformación con el ajuste de mínimos cuadrados que permitan transformar coordenadas planas desde un sistema local a un sistema global, dio como resultado que son compatibles con escalas mayores a 1:5000, pero se debe tomar en consideración que genera errores sistemáticos que se evidencian en el rango de amplitud entre el mínimo y máximo valor, además que hay discontinuidades en los resultados como se pudieron observar en la figura 4.2.
- En la comparación entre el cálculo de coordenadas con parámetros de transformación y redes neuronales artificiales, se evidenció que el mejor resultado en cuanto se refiere a precisión, homogeneidad de resultados, porcentaje de validación y rango de amplitud entre la distorsión mínima y máxima, se obtiene justamente con la segunda opción que son redes neuronales artificiales.

5.2. RECOMENDACIONES

- Queda abierta la posibilidad de emplear otro tipo de redes neuronales artificiales, como por ejemplo redes recurrentes, además de variar los algoritmos de aprendizaje y optimización numérica en el entrenamiento de la red, a fin de lograr mejores precisiones en los resultados.
- La transformación que emplea parámetros de transformación la cual se la puede realizar matemáticamente así como también espacialmente con la ayuda de un Sistema de Información Geográfica (en este caso gvSIG con la opción del Sextante) y así poder visualizar la cartografía digital transformada para trabajar sobre ella, pero, la transformación que se realiza con redes neuronales artificiales aún no ha desarrollado un comando o programa que permita visualizar la transformación de manera espacial, aunque gracias al progreso de softwares libres se puede crear una línea de sentencia que solvente esta necesidad de transformar espacialmente los resultados obtenidos con una red neuronal artificial.

REFERENCIAS BIBLIOGRÁFICAS.

- Chacón, Alexandra, “Predicción de ondulaciones geoidales a través de una red neuronal artificial en un área del Distrito Metropolitano de Quito”, 2010.
- Chandra, Pravin, “Sigmoidal Function Classes for Feedforward *Artificial Neural Networks*”, 2003.
- Daza, S., Redes neuronales, <http://www.monografias.com/trabajos12/redneur/redneur.shtml>, 2008-10, 2012-10.
- Distrito Metropolitano de Quito, Ordenanza Metropolitana N° 0225, 2007.
- Dreyfus, G., “Neural Networks. Methodology and Applications”, pág. 193-194, 2004.
- Escalona, Pamela, & Iturra, Sonia, “Análisis de la metodología de transformación de PSAD56 a SIRGAS en el catastro minero de la zona de Til-Til”, 2006.
- Gershenson Carlos, “Artificial Neural Networks for beginners”, 2003.
- Gonzáles, Giraldo, “Cartografía catastral y planeación urbana y regional”, Revista de Información y Análisis, num 18, México 2002.
- Haykin. S., “Neural Networks a comprehensive foundation”, 2da edición, 2005.
- Hernández, Nuria, “Redes de Neuronas Artificiales en Oceanografía”, 2004.
- Hudson, M., et al, “Neural Network Toolbox, Guía de usuario de Matlab”, 2012.
- Hwang, J., “Regression Modeling in Back-Propagation and Projection Pursuit Learning”, 1994.
- INEGI, *El cambio de Marco de Referencia Terrestre Internacional (ITRF) en México*, Abril, 2011.
- Instituto Geográfico Agustín Codazzi, *Parámetros oficiales de transformación para migrar a MAGNA-SIRGAS la información existentes en Datum BOGOTÁ*, 2004.

- Instituto Geográfico Militar – Ecuador, Atlas Universal y del Ecuador Tomo 1, 2005.
- Leiva, César, “ Determinación de parámetros de transformación entre los Sistemas PSAD56 y WGS84 para el país”, 2003.
- Llano, Luis, et al, “Comparación del desempeño de funciones de activación en redes feedforward para aproximar funciones de datos con y sin ruido”, 2007.
- Molina, Leonardo, “Validación de modelos de transformación bidimensional para compatibilizar bases cartográficas escala 1:10000”, Curitiba, 2007.
- Nacelle Andrés, “Redes Neuronales Artificiales”, 2009.
- Najah, A., El-Sahfie, A., Karim, O. & El-Sahfie H., “Application of Artificial Neural Network for water quality prediction”, 2012.
- Pallejá, Ezequiel, “*Sistemas Geodésicos de Referencia*”, 1ra edición, Comité Nacional de la Unión Geodésica y Geofísica Internacional, 1999.
- Passos, Geraldo, “Formación Continua en Georreferenciación aplicada al catastro rural”, 2005.
- Pérez, Juan, “Apuntes de Fotogrametría II”, Mérida, 2001.
- Pérez, Roberto, “Parámetros de transformación entre el Sistemas SIRGAS95 y los sistemas locales CDM y ROU-USAMS (Yacaré)”, 2002.
- Rezeai, K., et al., “Feed Forward Neural Network and Interpolation Function Models to Predict the Soil and Subsurface Sediments Distribution in Bam, Iran”, 2009.
- Rodríguez, Ruben, Brunini, Claudio & Olondriz, Javier, “El problema de la determinación de parámetros de transformación”, Universidad Nacional de la Plata, 1997.
- Rojas, Raúl, “Neural Network. A systematic Introduction”, 1996.
- Romero, Ricardo & Tierra, Alfonso, “Parámetros de transformación entre sistemas de referencia proyectados UTM-PSAD56 Y SIRGAS00 para escalas catastrales”, 2012.

- Salao, José, “Estudio de las técnicas de Inteligencia Artificial mediante el apoyo de un software educativo”, 2009.
- Santacruz, Andrea, “Transformación entre el sistema PSAD56 y los marcos de referencia ITRF utilizando modelos de Helmert y velocidades de placas tectónicas VEMOS”, 2010.
- SIRGAS, Página web Oficial de SIRGAS, www.sirgas.org, Fecha de ingreso, enero 2013.
- Tierra, Alfonso, “Estado actual del cambio para el Sistema de Referencia Geocéntrico SIRGAS95 en el Ecuador”, 2007.
- Tierra, Alfonso, “Transformación entre los sistemas geodésicos PSAD56 y SIRGAS usando una Red Neuronal Artificial”, 2009.
- Tierra, Alfonso, “Evaluación del EGM08 y EGM06 en el Ecuador a partir de datos GPS y nivelación geométrica”, 2009.
- Universidad Nacional de La Plata - Facultad de Ciencias Astronómicas y Geofísicas, 2012.