

**UNIVERSIDAD NACIONAL DEL ALTIPLANO  
FACULTAD DE CIENCIAS AGRARIAS  
ESCUELA PROFESIONAL DE INGENIERÍA TOPOGRÁFICA Y  
AGRIMENSURA**



**“GENERACIÓN DE MODELO DIGITAL DE ELEVACIONES (MDE) DE  
ONDULACIONES GEOIDALES USANDO EL METODO GNSS/NIVELACIÓN  
Y REDES NEURONALES ARTIFICIALES A PARTIR DE DATOS  
DISPERSOS”**

**TESIS**

PRESENTADA POR:

**HEBER LLANO CRUZ**

**JORGE LUIS GONZALES ACEITUNO**

PARA OPTAR EL TÍTULO PROFESIONAL DE:

**INGENIERO TOPÓGRAFO Y AGRIMENSOR**

PROMOCIÓN: 2012-II, 2014-I

**PUNO – PERÚ**

**2018**

**UNIVERSIDAD NACIONAL DEL ALTIPLANO  
FACULTAD DE CIENCIAS AGRARIAS  
ESCUELA PROFESIONAL DE INGENIERÍA TOPÓGRAFICA Y  
AGRIMENSURA**

**“GENERACIÓN DE MODELO DIGITAL DE ELEVACIONES (MDE) DE  
ONDULACIONES GEODALES USANDO EL METODO GNSS/NIVELACIÓN Y  
REDES NEURONALES ARTIFICIALES A PARTIR DE DATOS DISPERSOS”**

**TESIS**

PRESENTADA POR:

**HEBER LLANO CRUZ**

**JORGE LUIS GONZALES ACEITUNO**



PARA OPTAR EL TÍTULO PROFESIONAL DE:

**INGENIERO TOPOGRAFO Y AGRIMENSOR**

FECHA DE SUSTENTACIÓN: 15 DE JUNIO DE 2018

APROBADA POR EL JURADO REVISOR CONFORMADO POR:

PRESIDENTE	:	 <hr/> Ing. M.Sc. Luis Alberto Mamani Huanca
PRIMER MIEMBRO	:	 <hr/> Ing. Victor Cipriano Flores Flores
SEGUNDO MIEMBRO	:	 <hr/> Ing. Angel Abraham Franco Pineda
DIRECTOR / ASESOR	:	 <hr/> Ing. Arturo Joels Ventura Mamani

PUNO – PERÚ

2018

**Área : Ciencias naturales**

**Tema : Topografía geodesia, cartografía y catastro**

**DEDICATORIA**

*A Dios: por permitirme tener la fuerza para terminar mi carrera.*

*A mi querida madre Lorenza Sofía Cruz Cahuana: por su amor incondicional, por su esfuerzo en concederme la oportunidad de estudiar y por su constante apoyo a lo largo de mi vida.*

*A mi esposa y mis hijas: Por ser la razón de mí existir sin ellos la fuerza de levantarme cada día para ser mejor persona no sería una realidad, gracias Betsy, Gabriela y Luciana por existir.*

*A mis amigos y parientes: por sus consejos, paciencia y toda la ayuda que me brindaron para concluir mis estudios.*

**Heber**

**DEDICATORIA**

*A mis padres Julian y Antusa, por los principios y valores que impregnaron en mi persona, por su amor y apoyo incondicional.*

*A mis hermanos Yurhi y Lidia Yanira, por la fraternidad, cariño y lealtad que depositaron en mí.*

*Y en especial a mi compañera de toda la vida Elizabet, por haberme dado lo más hermoso en la vida, nuestra bella hija Danna Sugehi, la razón de mi superación.*

**Jorge Luis**



## AGRADECIMIENTO

A la Universidad Nacional del Altiplano, a los docentes y trabajadores administrativos de la Escuela Profesional de Ingeniería Topográfica y Agrimensura, quienes aportaron y contribuyeron con sus conocimientos en nuestra formación profesional.

Al M.Sc, Luis Alberto Mamani Huanca, Ing. Victor Cipriano Flores Flores, Ing. Angel Abraham Franco Pineda, Ing. Arturo Joels Ventura Mamani. Quienes supieron dirigirnos de una manera desinteresada en la elaboración y ejecución del presente trabajo.

**ÍNDICE GENERAL**

	Pág.
<b>ÍNDICE DE FIGURAS</b>	
<b>ÍNDICE DE TABLAS</b>	
<b>ÍNDICE DE ACRÓNIMOS</b>	
<b>RESUMEN .....</b>	<b>12</b>
<b>ABSTRACT.....</b>	<b>13</b>
<b>I. INTRODUCCIÓN.....</b>	<b>14</b>
<b>1.1 PLANTEAMIENTO DEL PROBLEMA.....</b>	<b>15</b>
<b>1.2 ANTECEDENTES .....</b>	<b>16</b>
<b>1.3 HIPOTESIS GENERAL .....</b>	<b>18</b>
1.3.1 HIPÓTESIS ESPECÍFICOS. ....	18
<b>1.4 VARIABLES INDEPENDIENTES.....</b>	<b>19</b>
<b>1.5 VARIABLES DEPENDIENTES. ....</b>	<b>19</b>
<b>1.6 OBJETIVO GENERAL: .....</b>	<b>19</b>
1.6.1 OBJETIVOS ESPECÍFICOS:.....	19
<b>II. REVISIÓN DE LITERATURA .....</b>	<b>20</b>
<b>2.1 SISTEMAS DE REFERENCIA .....</b>	<b>20</b>
2.1.1 GEODESIA.....	21
2.1.2 EL GEOIDE.....	22
2.1.3 ELIPSOIDE DE REVOLUCIÓN. ....	25
<b>2.2 METODOS PARA LA OBTENCION DEL GEOIDE.....</b>	<b>27</b>
2.2.1 MÉTODO GEOMÉTRICO PARA LA OBTENCIÓN DEL GEOIDE.....	28
2.2.2 ALTURAS NIVELADAS. ....	28
2.2.3 ALTURAS ELIPSOIDALES. ....	29
2.2.4 NIVELACIÓN.....	30
2.2.5 SISTEMA DE ALTURAS.....	31
2.2.6 SISTEMA DE ALTURAS EN EL PERÚ .....	32
<b>2.3 FUNDAMENTOS DEL SISTEMA GPS Y APLICACIONES EN LA TOPOGRAFÍA .....</b>	<b>35</b>
2.3.1 FUNDAMENTO SOBRE EL SISTEMA.....	35
2.3.2 MÉTODO DIFERENCIAL. ....	36
2.3.3 POSICIONAMIENTO GPS MÉTODOS Y APLICACIONES. ....	37
2.3.4 RECEPTOR DE FORMATO INDEPENDIENTE DE INTERCAMBIO (RINEX).....	40
<b>2.4 RED NEURONAL ARTIFICIAL (RNA) .....</b>	<b>41</b>
2.4.1 HISTORIA DE LA REDES NEURONALES ARTIFICIALES. ....	42
2.4.2 NEURONA BIOLÓGICA. ....	44
2.4.3 NEURONA ARTIFICIAL.....	47
2.4.4 RED NEURONAL ARTIFICIAL. ....	49
2.4.5 ESTRUCTURA DE UNA RED NEURONAL ARTIFICIAL. ....	52

2.4.6 APRENDIZAJE DE LA RED NEURONAL ARTIFICIAL. ....	54
2.4.7 TIPOS DE ESQUEMAS DE APRENDIZAJE:.....	55
2.4.8 PERCEPTRÓN. ....	57
2.4.9 FUNCIONES DE TRANSFERENCIA .....	61
2.4.10 ARQUITECTURA DE UNA RED NEURONAL ARTIFICIAL. ....	62
2.4.11 RED NEURONAL MULTICAPA. ....	64
<b>III. MATERIALES Y MÉTODOS.....</b>	<b>66</b>
<b>3.1 EQUIPOS Y MATERIALES .....</b>	<b>66</b>
3.1.1 EQUIPOS.....	66
3.1.2 MATERIALES. ....	67
3.1.3 HERRAMIENTAS INFORMÁTICAS. ....	67
<b>3.2 DESARROLLO METODOLÓGICO .....</b>	<b>68</b>
3.2.1 DELIMITACIÓN DEL ÁREA DE ESTUDIO .....	68
<b>3.3 DATOS NECESARIOS .....</b>	<b>69</b>
<b>3.4 DATOS EXISTENTES.....</b>	<b>69</b>
3.4.1 PUNTOS GNSS .....	69
3.4.2 ALTURA NIVELADA.....	70
<b>3.5 OBTENCION DE DATOS .....</b>	<b>70</b>
3.5.1 POSICIONAMIENTO DE PRESICION.....	70
3.5.2 NIVELACION GEOMETRICA.....	74
<b>3.6 ENTRENAMIENTO DE RED NEURONAL.....</b>	<b>78</b>
3.6.1 DEFINICIÓN DE SUB CONJUNTO DE ENTRENAMIENTO.....	78
3.6.2 ESTRUCTURA DE LA RED NEURONAL ARTIFICIAL.....	82
3.6.3 PREDICCIÓN DE ONDULACIONES GEOIDALES EN PUNTOS DE EVALUACIÓN.....	91
3.6.4 PREDICCIÓN DE ONDULACIONES GEOIDALES CON COORDENADAS NORTE Y ESTE.....	92
3.5.5 ELABORACIÓN DE MODELO DIGITAL DE ELEVACIONES DE LAS ONDULACIONES GEOIDALES PREDECIDAS .....	97
<b>IV. RESULTADOS Y DISCUSIÓN.....</b>	<b>100</b>
<b>4.1 MÉTODO DE INVESTIGACIÓN.....</b>	<b>100</b>
<b>4.2 POBLACIÓN Y MUESTRA.....</b>	<b>100</b>
<b>4.3 COMPARACIÓN DE RESULTADOS.....</b>	<b>100</b>
4.3.1 DATOS EXPERIMENTALES. ....	100
4.3.2 DATOS DESCRIPTIVOS. ....	102
<b>4.4 PRUEBA T PARA DOS MUESTRAS INDEPENDIENTES RNA “NEH”.....</b>	<b>105</b>
<b>4.5 PRUEBA T PARA DOS MUESTRAS INDEPENDIENTES RNA “NE”... ..</b>	<b>107</b>
<b>CONCLUSIONES .....</b>	<b>109</b>
<b>RECOMENDACIONES .....</b>	<b>111</b>
<b>REFERENCIAS.....</b>	<b>112</b>
<b>GLOSARIO.....</b>	<b>115</b>
<b>ANEXOS.....</b>	<b>119</b>

## ÍNDICE DE FIGURAS

	Pág.
Figura N° 1: Forma Tridimensional del Geoide de la Tierra.....	23
Figura N° 2: Comparación entre el Elipsoide y Geoide .....	24
Figura N° 3: Comparación Elipsoide, Geoide, Superficie topográfica, EGM96 EGM08 Fuente: elaboración propia.....	24
Figura N° 4: Comparaciones entre el Elipsoide, Geoide y la Superficie terrestre .....	26
Figura N° 5: Comparación de los sistemas GPS, GLONASS, GALILEO, COMPAS ..	27
Figura N° 6: Alturas niveladas.....	29
Figura N° 7: Superficies de referencia.....	30
Figura N° 8: Principio básico de la nivelación geométrica Fuente (Carrión Sánchez, 2013) .....	31
Figura N° 9: Red Nacional de nivelación de alta precisión (NAP) .....	35
Figura N° 10: Método Diferencial.....	36
Figura N° 11: Mascara de Elevación .....	37
Figura N° 12: Línea Base.....	38
Figura N° 13: Formato de denominación de los ficheros RINEX .....	40
Figura N° 14: Estructura de una neurona Biológica .....	46
Figura N° 15: Modelo de Neurona Artificial.....	48
Figura N° 16: Estructura de una red neuronal de tres capas .....	53
Figura N° 17: Estructura general de una neurona del tipo perceptrón.....	59
Figura N° 18: Discriminación de clases por un Perceptrón.....	59
Figura N° 19: Función de transferencia .....	61
Figura N° 20: Funciones de activación.....	61
Figura N° 21: Esquema de topología feedforward .....	63
Figura N° 22: Arquitectura de una Red Neuronal Multicapa .....	65
Figura N° 23: Perímetro de Área de estudio Fuente: Elaboración propia. ....	68
Figura N° 24: Visualización de Líneas Base .....	71
Figura N° 25: Entorno Trimble Busines Center 3.50 .....	71
Figura N° 26: Entorno de Microsurvey Starnet para la compensación de Nivelación Versión de prueba de 10 días .....	75
Figura N° 27: Sub Conjuntos de entrenamiento Fuente: Elaboración propia.....	80
Figura N° 28: Estructura de la red neuronal artificial Fuente: Elaboración propia. ....	82
Figura N° 29: Entorno Matlab más escript para preprocesado de datos (Ver. de prueba) Fuente: Elaboración propia .....	83
Figura N° 30: Toolbox Entrenador de Datos y Redes - Matlab 2015.....	84
Figura N° 31: Configuración de la RNA .....	85
Figura N° 32: Red diseñada.....	86
Figura N° 33: Pesos sinápticos y bias .....	87
Figura N° 34: Parámetros de entrenamiento .....	87
Figura N° 35: Entrenamiento de red .....	88
Figura N° 36: Reporte de Entrenamiento .....	89

Figura N° 37: Curva de aprendizaje de la RNA .....	91
Figura N° 38: Arquitectura de RNA para entradas norte y este Fuente: Elaboración propia. ....	92
Figura N° 39: Arquitectura DEM .....	93
Figura N° 40: Parámetros de entrenamiento Fuente: Elaboración propia. ....	94
Figura N° 41: Reporte de entrenamiento Fuente: Elaboración propia.....	95
Figura N° 42: Generación de puntos norte y este Fuente: Elaboración propia.....	97
Figura N° 43: Plataforma Golden Surfer 13 (Ver. Prueba) Fuente: Elaboración propia.97	
Figura N° 44: Datos para modelamiento Fuente: Elaboración propia. ....	98
Figura N° 45: Plano planta de ondulaciones Fuente: Elaboración propia. ....	98
Figura N° 46: Gráfica de elevaciones Fuente: Elaboración propia. ....	99
Figura N° 47: Plano en perspectiva Fuente: Elaboración propia.....	99
Figura N° 48: Modelo 3D de las ondulaciones geoidales por el método RNA Fuente: Elaboración propia.....	99
Figura N°49 Tabla de distribución t .....	106

## ÍNDICE DE TABLAS

	Pág.
Tabla N°1 Parámetros del Elipsoide de Referencia.....	26
Tabla N°2 Especificaciones Técnicas GNSS Base y Rover .....	66
Tabla N°3 Especificaciones Técnicas nivel Leica N720 .....	67
Tabla N°4 Coordenadas geográficas y altura elipsoidal Base PN01 .....	70
Tabla N°5 Altura nivelada, Red de Nivelación Nacional .....	70
Tabla N°6 Reporte de Post Procesamiento de Línea Base .....	72
Tabla N°7 Reporte de Coordenadas Geográficas y Alturas Elipsoidales .....	72
Tabla N°8 Reporte de Coordenadas UTM y Alturas Geoidales EGM96 .....	73
Tabla N°9 Circuito de nivelación I.....	75
Tabla N°10 Circuito de nivelación II.....	75
Tabla N°11 Circuito de nivelación III .....	76
Tabla N°12 Observaciones y residuos ajustados (metros).....	76
Tabla N°13 Alturas Ajustadas y propagación de errores (metros) .....	77
Tabla N°14 Alturas Niveladas (H).....	77
Tabla N°15 Lista de Puntos para Entrenamiento.....	80
Tabla N°16 Subconjunto de Entrenamiento .....	81
Tabla N°17 Subconjunto Test.....	81
Tabla N°18 Datos para la capa de entrada .....	82
Tabla N°19 Datos para la capa de salida .....	83
Tabla N°20 Ondulaciones conocidas y predecidas.....	89
Tabla N°21 Pesos Sinápticos antes del entrenaminto .....	90
Tabla N°22 Pesos Sinápticos después del entrenamiento.....	90
Tabla N°23 Predicción de ondulaciones geoidales en puntos de evaluación .....	92
Tabla N°24 Datos de capa de entreada para entrenamiento .....	93
Tabla N°25 Datos de capa de salida .....	94
Tabla N°26 Predicción de ondulaciones con entradas norte y este (Train) .....	96
Tabla N°27 Predicción de ondulaciones con entradas norte y este (Test).....	96
Tabla N°28 Precisiones de posicionamiento GNSS .....	100
Tabla N°29 Datos de Nivelación y residuales .....	101
Tabla N°30 Comparación de ondulaciones geoidales obtenidas a través de GNSS/Nivelación y RNA con entradas (norte, este, altura elipsoidal). .....	102
Tabla N°31 Estadísticos de ondulaciones geoidales obtenidas a través de RNA con entrada (Norte, Este y altura elipsoidal) .....	103
Tabla N°32 Comparación de ondulaciones geoidales obtenidas a través de GNSS/Nivelación y RNA obtenida con entradas (Norte y Este).....	104
Tabla N°33 Estadísticos de ondulaciones geoidales obtenidas a través de RNA con entrada (Norte y Este) .....	104

## ÍNDICE DE ACRÓNIMOS

**ERP.** Estación de Rastreo Permanente

**GNSS.** Global Navigation Satellital System (Sistema Satelital de Navegación Global)

**REGGEN.** Red Geodésica Geocéntrica Nacional.

**SIRGAS.** Sistema de Referencia Geocéntrica para las Américas.

**WGS-84.** World Geodetic System de 1984. (Sistema Geodésico Mundial 1984)

**MSNMM.** Metros sobre el nivel medio del mar

**RNA.** Red Neuronal Artificial.

**IGN.** Instituto Geográfico Nacional.

**EGM96.** Earth Gravitational Model 1996.

**EGM08.** Earth Gravitational Model 2008.

**BM.** Bench Mark (banco de nivel).

## RESUMEN

Además de conocer las coordenadas UTM (Este y Norte) de cualquier punto de la superficie terrestre surge la necesidad de obtener con precisión el valor de la altura referida al nivel medio de los mares (alturas ortométricas), debido a su aplicación práctica en diversas obras de ingeniería. Es por tal motivo que el objetivo del presente proyecto es generar un modelo digital de elevaciones (MDE) de las ondulaciones geoidales, aplicando el método GNSS/nivelación a través del entrenamiento y aprendizaje de redes neuronales artificiales utilizando la interfaz gráfica del software Matlab, el proyecto se encuentra ubicado en un sector de la ciudad de Puno, en la zona norte del área urbana con una extensión de 144 has.

La formulación de modelos de ondulaciones geoidales se lleva a cabo a través de cálculos que combinan el posicionamiento GNSS para las alturas elipsoidales y nivelación geométrica para las alturas ortométricas (a través de la relación  $N=h-H$ ).

El aprendizaje de la red es de tipo supervisado utilizando una red del tipo backpropagation, culminado el entrenamiento, la red neuronal artificial tiene la capacidad de predecir ondulaciones geoidales (N), a partir de entradas norte y este, seguidamente generamos puntos norte y este uniformemente distribuidos (grillado) a cada 50m dentro del perímetro de estudio, éste último para la generación del modelo digital de elevaciones (MDE). Comprobado la capacidad predictiva de la RNA, se procede a realizar pruebas de validación con un grupo de puntos (test), grupo que no forma parte del entrenamiento. Las precisiones predecidas, tienen una desviación estándar de 0.03831m, haciendo un análisis de varianza  $t$  de student, se determinó que no existe diferencia significativa respecto a las ondulaciones conocidas, con el cual se concluye que es aplicable dentro del área de estudio.

**Palabras Clave:** Ondulación Geoidal, Red Neuronal Artificial.



## ABSTRACT

In addition to knowing the UTM coordinates (East and North) of any point on the surface of the earth, there is a need to accurately obtain the value of the height referred to the mean level of the seas (orthometric heights), due to its practical application in various works of engineering. It is for this reason that the objective of this project is to generate a digital elevation model (MDE) of the geoid waves, applying the GNSS / leveling method through the training and learning of artificial neural networks using the graphical interface of the Matlab software, the project is located in a sector of the city of Puno, in the northern area of the urban area with an area of 144 hectares.

The formulation of geoidal wave models is carried out through calculations that combine GNSS positioning for ellipsoidal heights and geometric leveling for orthometric heights (through the  $N = h - H$  ratio).

The learning of the network is supervised type using a backpropagation network, training is completed, the artificial neural network has the ability to predict geoid waves (N), from north and east entries, then we generate points north and east uniformly distributed (grilled) to each 50m within the perimeter of the study, the latter for the generation of the digital elevation model (MDE). Once the predictive capacity of the RNA has been verified, validation tests are carried out with a group of points (test), a group that is not part of the training. The predicted accuracies, have a standard deviation of 0.03831m, making an analysis of student variance t, it was determined that there is no significant difference with respect to the known undulations, with which it is concluded that it is applicable within the study area.

**Keywords:** Geoid Undulation, Artificial Neural Network.

## I. INTRODUCCIÓN

En los últimos años, el avance de las tecnologías geoespaciales ha cambiado de manera radical la percepción del mundo. La gran precisión a la hora de medir las variables geométricas y físicas de la Tierra, ha permitido determinar modelos fieles a las dinámicas propias del planeta. Sin embargo, al tratar un sistema tan complejo y al reducir la escala de captura de los datos, cómo solución de problemas locales, es necesaria la integración de nuevas y mejores técnicas, que permitan elevar los niveles de detalle de la información espacial, para lograr una buena estimación de las variables que intervienen en determinado proceso.

Las mediciones GNSS, tienen altas posibilidades de operabilidad, a cualquier hora y bajo las condiciones propias del entorno, además de ser una técnica económica que ofrece precisiones de pocos centímetros, por medio de técnicas diferenciales, en coordenadas horizontales (latitud y longitud); sin embargo, la precisión no es tan alta en medidas verticales.

Al comparar mediciones de alturas referidas al nivel medio del mar, con precisiones muy altas, a través de técnicas clásicas de la geodesia y alturas medidas con dispositivos GNSS, se encuentran grandes diferencias, debido a que están medidas con respecto a dos superficies diferentes: El elipsoide que es una Figura idealizada, que se aproxima a la figura de la tierra, y por otro lado una superficie equipotencial de referencia (EGM), que sufre alteraciones y deformaciones por fuerzas físicas.gravitacionales. Esta diferencia es el resultado de las variaciones de gravedad presente en el área de observación.

La técnica clásica de Geodesia para obtener alturas, es la nivelación geométrica, que consiste en la medición de desniveles entre dos puntos. Esta técnica, que provee

precisiones muy altas, tiene el inconveniente de ser costosa, y prácticamente imposible de llevar a cabo en las zonas montañosas.

Debido a la implementación de las tecnologías GNSS, ha surgido la necesidad de combinar las dos técnicas de posicionamiento horizontal y vertical, facilitando el cálculo de alturas ortométricas.

Si se tiene presente que existe una relación entre las dos variables, es posible determinar un modelo basado en datos, utilizando algoritmos (activación y transferencia) de sistemas inteligentes que permitan modelar las variables dependientes (salida), en torno a las otras (entradas). Al desarrollar un buen modelo, que cuente con una precisión que satisfaga los requerimientos de trabajos en geociencias, es posible obtener alturas niveladas, en zonas donde no se cuente con puntos de nivelación, en donde realizar mediciones directas resulta costoso y prácticamente imposible. Por ejemplo, si se tiene posición a través de un dispositivo de captura GNSS, es decir coordenadas latitud, longitud y altura elipsoidal, en combinación con un modelo geoidal, se puede determinar la altura nivelada.

## **1.1 PLANTEAMIENTO DEL PROBLEMA**

Dentro del ámbito de las ciencias de la tierra, la determinación de una superficie de referencia para las alturas ha sido siempre un tema de interés, en este contexto se ha desarrollado múltiples técnicas y metodologías para establecer dicha superficies de referencia sobre la cual es posible basar las mediciones de altura a nivel local.

De forma tradicional las alturas y desniveles se han medido considerando como superficie de referencia el nivel medio del mar, es así que cada país se ha valido de los registros de uno o varios mareógrafos localizados en sus costas para la determinación

del mismo, tomando observaciones como el “cero” o punto de partida de su red de nivelación. (Carrion Sanchez, 2013).

La construcción de estas redes de nivelación demandan gran esfuerzo debido a las características metodológicas de trabajo necesario para su establecimiento, y su uso en la práctica presenta ciertos inconvenientes entre los cuales se puede señalar que proporcionan únicamente información discreta de variación de altura con respecto al nivel medio del mar (nmm). Se puede advertir que no existe compatibilidad entre dos o más redes de nivelación que hayan sido generados partiendo de distintos mareógrafos.

Por los motivos antes expuestos, que hacen referencia a las limitaciones de las redes de nivelación clásicas, en la actualidad se pretende llegar a conocer la superficie de referencia para las alturas que tengan características globales, es decir que las información que proporcionan las diferentes redes altimétricas puedan ser usadas en forma conjunta con objetivo de poder realizar estudios y trabajos a nivel local, regional y nacional sin que exista discrepancia entre los datos recabados.

Es por tanto necesario generar un modelo digital de elevación (MDE) de ondulaciones geoidales en base a la información obtenida de una red altimétrica (GNSS/Nivelación) generada por Redes Neuronales Artificiales (RNA).

## 1.2 ANTECEDENTES

En marzo de 2013 fue presentado en la Facultad de Ciencias Astronómicas y Geofísicas de la Universidad Nacional de la Plata – Argentina, el proyecto de investigación “GENERACIÓN DE UNA MALLA DE ONDULACIONES GEOIDALES POR EL MÉTODO GPS/NIVELACIÓN Y REDES NEURONALES ARTIFICIALES A PARTIR DE DATOS DISPERSOS” para optar el Grado Académico de Magister en Geomática.

El área en la cual se desarrolla el trabajo, corresponde a una región delimitada en función de la distribución espacial de los datos, la misma incluye provincias de la región Sierra y Costa del Ecuador Continental.

El área total aproximada abarca 24344.48 Km<sup>2</sup>, correspondiendo un 60.63 % de la misma a la región costa, en donde se registran las menores altitudes y un 39.37% a la región Sierra, que posee los valores de altitud más altos y un relieve marcadamente irregular. Entre estas dos regiones geográficas, a manera de límite natural, se encuentra atravesando de norte a sur la cordillera de los Andes.

Con el método GPS/nivelación y redes neuronales artificiales fue posible obtener un modelo geoidal local que representa las observaciones disponibles de ondulación geoidal mejor que 0.09 m. (Jose Luis Carrion, 2013).

En febrero de 2010 fue presentado la Facultad de Ingeniería Geográfica y Medio Ambiente de la Escuela Politécnica del Ejercito, el proyecto de investigación “PREDICCIÓN DE ONDULACIONES GEOIDALES A TRAVÉS DE UNA RED NEURONAL ARTIFICIAL EN UN ÁREA DEL DISTRITO METROPOLITANO DE QUITO” para optar el Grado Académico de Ingeniero.

A más de conocer las coordenadas UTM (Este y Norte) o coordenadas geodésicas (latitud y longitud) de cualquier punto de la superficie terrestre surge la necesidad de obtener con precisión el valor de la altura referida al nivel medio de los mares, debido a su aplicación práctica en diversas obras de ingeniería. Por ello se investiga metodologías que pueda entregar buenos resultados en lo que a precisiones se refiere, siendo para el presente estudio la predicción de ondulaciones geoidales a través del entrenamiento de una red neuronal artificial en un área aproximada de 490 Km<sup>2</sup> del

Distrito Metropolitano de Quito, a través de un aprendizaje supervisado utilizando el algoritmo de retropropagación del error (backpropagation).

Durante el entrenamiento de la red neuronal para el patrón de entrada correspondiente a las 8 observaciones se puede concluir que no existió una diferencia importante entre los valores de media (0.6 cm) y desviación estándar (8 cm) con los obtenidos a través del modelo matemático. Mientras que para el set de entrenamiento correspondiente a las 234 observaciones se pudo apreciar que se optimiza los datos estadísticos, en donde se obtuvo una desviación estándar de 3.10 cm y una media de 0.1 cm. (Silva, 2010)

### **1.3 HIPOTESIS GENERAL**

1. La generación de un modelo digital de elevación (MDE) de ondulación Geoidal en base a la información obtenida usando el método (GNSS/NIVELACION) generada por Redes Neuronales Artificiales (RNA) permite la obtención de alturas ortométricas necesarias para Proyectos de Topografía

#### **1.3.1 Hipótesis específicos**

1. La aplicación del modelo geoidal generado por el método (GNSS/Nivelación) y redes neuronales artificiales, si es utilizable en el ámbito local.
2. Las ondulaciones geoidales obtenidas por el método (GNSS/Nivelación) y redes neuronales, cumplen con las aproximaciones y tolerancias respecto a otros modelos.

#### **1.4 Variables independientes**

Coordenadas geográficas latitud, longitud y altura elipsoidal, coordenadas UTM norte, este y altura geoidal, alturas niveladas.

#### **1.5 Variables dependientes.**

Ondulaciones geoidales.

#### **1.6 OBJETIVO GENERAL**

1. Generar un modelo digital de elevación (MDE) de ondulación Geoidal en base a la información obtenida de una red altimétrica (GNSS/Nivelación) generada por Redes Neuronales Artificiales (RNA)

##### **1.6.1 Objetivos específicos**

1. Aplicar el modelo Geoidal, con la finalidad de que una vez que la distribución espacial de los datos sea adecuada, pueda ser utilizada en el ámbito local.
2. Realizar un análisis comparativo de las aproximaciones de ondulaciones obtenidas y tolerancias respecto a ondulaciones conocidas y otros modelos geoidales.

## II. REVISIÓN DE LITERATURA

### 2.1 SISTEMAS DE REFERENCIA

La determinación de la posición de un punto sobre la superficie terrestre se hace posible teniendo como base un elemento de referencia, es decir un punto, línea o superficie que por convención se use para conformar un sistema de coordenadas, con el cual se establece la ubicación de cualquier punto sobre el planeta. Para muchos fines es suficiente el posicionamiento en el plano horizontal, sin embargo en la práctica también suele ser necesario contar con una posición en un sistema de referencia vertical. Cuando se necesita referenciar a un sistema de coordenadas puntos que se encuentran dentro de un área pequeña, es suficiente contar con un sistema de referencia local, cuyas coordenadas planas se encuentran referidas a un plano X – Y; sin embargo si se requiere abarcar áreas extensas de territorio, como por ejemplo una provincia o país, el sistema de referencia debe considerar variables como la forma no plana del planeta y la dinámica de sus elementos estructurales.

El sistema de referencia que hasta la actualidad ha mostrado mejor desempeño y que se aproxima a la forma terrestre es el elipsoide de revolución, éste cuenta como origen de coordenadas un dátum geocéntrico. El problema del posicionamiento en el plano horizontal queda resuelto con el uso de un elipsoide de referencia, sin embargo las alturas que proporciona este sistema de referencia están medidas desde una superficie matemática y no tienen relación con las alturas físicas que son necesarias en aplicaciones de ingeniería, en estos casos es apropiado referir la medición de alturas a una superficie cuya definición se enmarque dentro de los principios que rigen la física del planeta, dicha superficie se conoce como geoide. (EGM)



### 2.1.1 Geodesia

La geodesia es la ciencia que estudia la forma y dimensiones de la tierra. Esto incluye la determinación del campo gravitatorio externo de la tierra y la superficie del fondo oceánico. Dentro de esta definición, se incluye también la orientación y posición de la tierra en el espacio.

Una parte fundamental de la geodesia es la determinación de la posición de puntos sobre la superficie terrestre mediante coordenadas (latitud, longitud) y altura elipsoidal. La materialización de estos puntos sobre el terreno constituyen las redes geodésicas, conformadas por una serie de puntos (puntos de control geodésicos o también señales de nivelación). Con coordenadas que configuran la base de la cartografía de un país.

Los fundamentos físicos y matemáticos necesarios para su obtención, sitúan a la geodesia como una ciencia básica para otras disciplinas, como la topografía, fotogrametría, cartografía, ingeniería civil, navegación, sistemas de información geográfica, sin olvidar otros tipos de fines como los militares.

Desde el punto de vista del objetivo de estudio, se puede establecer una división de la geodesia en diferentes especialidades, aunque cualquier trabajo geodésico requiere la intervención de varias de estas subdivisiones:

**Geodesia geométrica:** Determinación de la forma y dimensiones de la Tierra en su aspecto geométrico, lo cual incluye fundamentalmente la determinación de coordenadas de puntos en su superficie.

**Geodesia física:** estudio del campo gravitatorio de la Tierra y sus variaciones, mareas (oceánicas y terrestres) y su relación con el concepto de altitud.

**Astronomía geodésica:** determinación de coordenadas en la superficie terrestre a partir de mediciones a los astros.


**Geodesia espacial:** determinación de coordenadas a partir de mediciones efectuadas a satélites artificiales (GNSS, VLBI, SLR, DORIS) y relación con la definición de sistemas de referencia.

**Microgeodesia:** medida de deformaciones en estructuras de obra civil o pequeñas extensiones de terreno mediante técnicas geodésicas de alta precisión.

### 2.1.2 El Geoide

El Geoide es un modelo físico que busca representar la verdadera forma de la tierra calculándola como una superficie de potencial de gravedad constante, es irregular debido a los efectos de variación en la densidad y distribución de masas de la Tierra, obedece de manera directa a los cambios en el campo de gravedad. Esta superficie irregular se utiliza convenientemente como la referencia para determinar la altura o elevación del terreno. La distancia vertical entre un punto cualquiera sobre el terreno y el geoide se denomina altura ortométrica y puede ser entendida como altura sobre el nivel medio del mar, en este sentido el geoide es parte fundamental de sistema de alturas. (Instituto Nacional Geográfico del Perú IGN, 2016)

Es la superficie equipotencial del campo de gravedad terrestre que mejor se ajusta al nivel medio del mar sin perturbaciones y que es perpendicular en todos sus puntos a la dirección de la gravedad y que se extiende de manera continua por debajo de los continentes. Es la superficie de nivel, equipotencial en el campo de la gravedad, que adopta la forma de esferoide irregular tridimensional. (Instituto Nacional Geográfico del Perú IGN, 2016)



*Figura N° 1: Forma Tridimensional del Geoide de la Tierra*

Fuente: (Administración Nacional de la Aeronáutica y del Espacio NASA, 2016).

En la imagen, las zonas en color rojo son por tanto regiones del geoide con mayor elevación y las azules son las más profundas.

El nivel medio del mar, a su vez, depende de las irregularidades en el campo gravitatorio de la Tierra, que alteran su posición. El agua de los océanos del globo busca estar en equilibrio y por ello tiende a seguir una superficie gravitatoria equipotencial.

Es por esto que se introduce una nueva figura llamada Geoide, definida como: la superficie equipotencial del campo gravitatorio de la Tierra que mejor se ajusta al nivel medio global del mar. Una de las consecuencias de esta definición es que el geoide es siempre perpendicular al vector de gravedad local en cada punto.

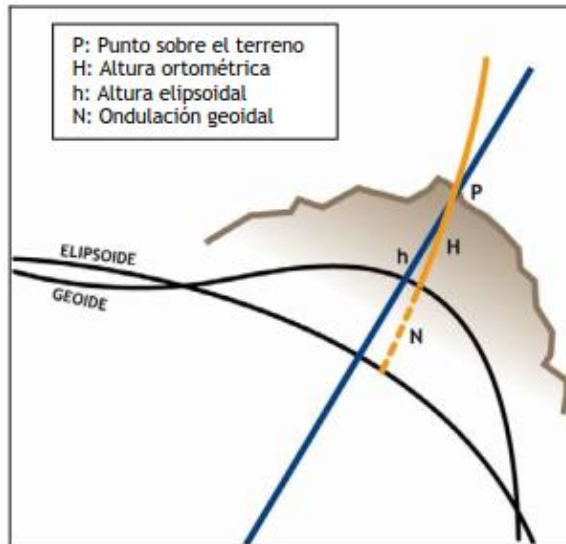


Figura N° 2: Comparación entre el Elipsoide y Geoide

Fuente: (Drewes & Sánchez, 2000)

$$N = h - H$$

**Ondulación Geoidal (N).**- Es la separación vertical entre el geoide y el elipsoide.

**Altura Ortométrica (H).**- Es la separación vertical entre el geoide y la superficie topográfica.

**Altura Elipsoidal (h).**- Es la separación vertical entre el elipsoide y la superficie de la topografía.

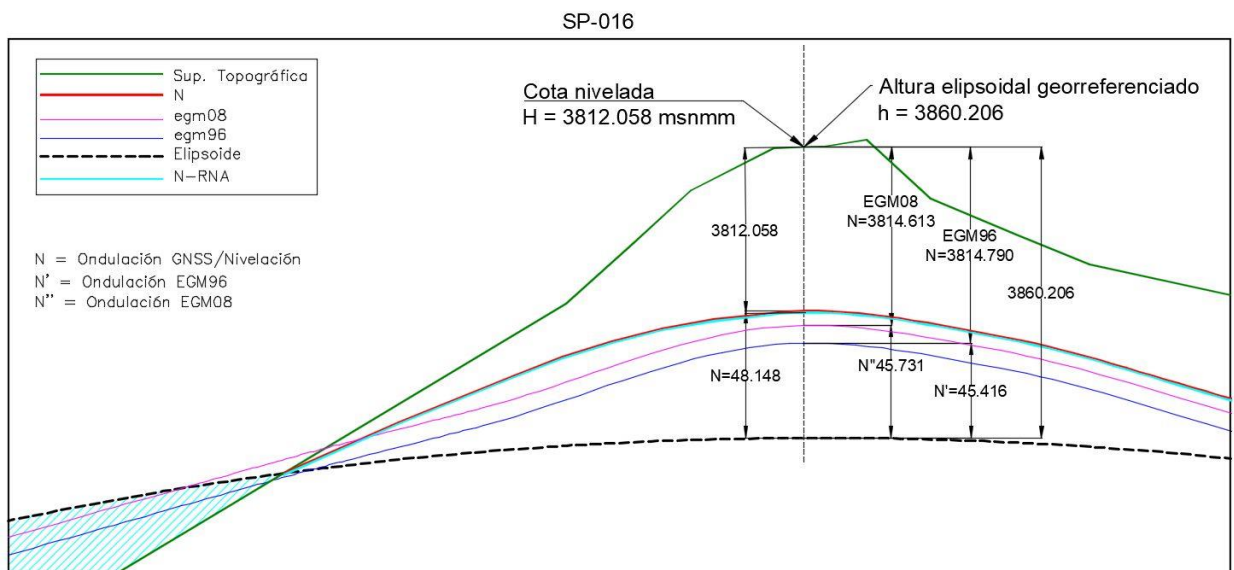


Figura N° 3: Comparación Elipsoide, Geoide, Superficie topográfica, EGM96 EGM08

Fuente: elaboración propia

### 2.1.3 Elipsoide de revolución

Es una figura matemática mediante el cual se representa de forma simplificada la tierra.

Debido a la concepción que se tiene de la Tierra que es ligeramente achatada en los polos y abultada en el Ecuador, se hace una semejanza con un elipsoide de revolución. Este elipsoide se genera haciendo girar una elipse alrededor de su eje menor (Ayala Ramírez & Hasbun Bardales, 2012).

Al especificar su forma y tamaño se define el elipsoide de revolución. Existen diferentes modelos de elipsoides utilizados en Geodesia, denominados elipsoides de referencia. Las diferencias entre éstos vienen dadas por los valores asignados a sus parámetros más importantes:

**Semieje ecuatorial (a) o Semieje mayor:** Longitud del semieje correspondiente al ecuador, desde el centro de masas de la Tierra hasta la superficie terrestre.

**Semieje polar (b) o Semieje menor:** Longitud del semieje desde el centro de masas de la Tierra hasta uno de los polos. Alrededor de este eje se realiza la rotación de la elipse base.

**Factor de achatamiento (f):** Este factor representa qué tan diferentes son los semiejes entre sí.

Su expresión es :  $f = \frac{a-b}{a}$

**Cuadrado de la 1ra Excentricidad:**  $e^2 = \frac{a^2 - b^2}{a^2}$

**Cuadrado de la 2da Excentricidad:**  $e'^2 = \frac{a^2 - b^2}{b^2}$

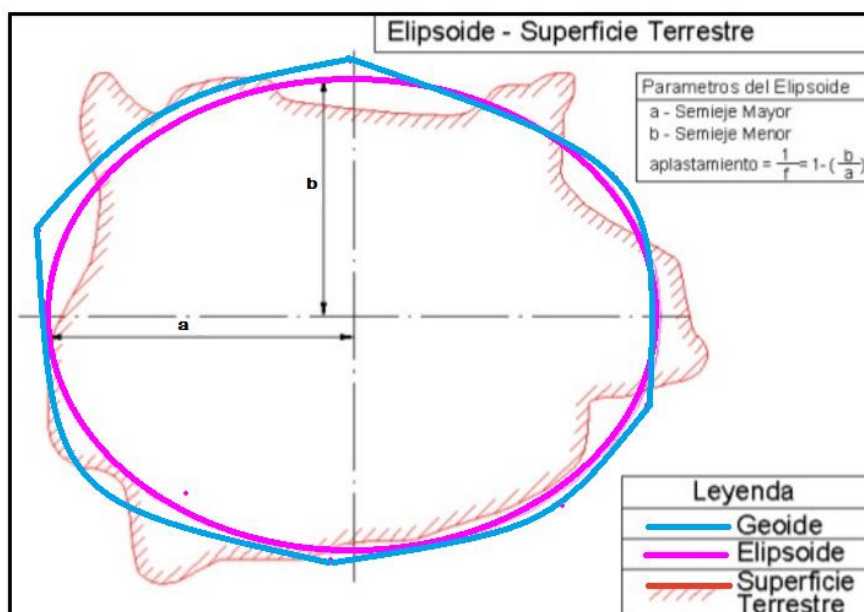


Figura N° 4: Comparaciones entre el Elipsoide, Geoide y la Superficie terrestre

Fuente: (Fernandez Coppel , 2001).

Tabla N°1

Parámetros del Elipsoide de Referencia

PARÁMETROS	ELIPSOIDE
	WGS 84
<i>a</i>	6 378 137 m
<i>b</i>	6 356 752.3142 m
<i>f</i>	0.003352811
<i>e</i> <sup>2</sup>	0.006694381
<i>e</i> ' <sup>2</sup>	0.006739497
Velocidad angular terrestre	7292115*10 <sup>-11</sup> rad/s
Constante gravitacional newtoniana	3986005*10 <sup>8</sup> m <sup>3</sup> s <sup>-2</sup>
Coficiente zonal armónico normalizado	-484.16685*10 <sup>-6</sup>

Fuente: (Instituto Nacional Geográfico del Perú IGN, 2016).

**2.2 METODOS PARA LA OBTENCION DEL GEOIDE**

La determinación del geoide consiste en encontrar aquella superficie equipotencial del campo de gravedad terrestre que mejor se aproxime al nivel medio de los mares. El campo de gravedad terrestre cuenta con infinitas superficies equipotenciales, de las cuales solo una de ellas será considerada por convención como la superficie de referencia para las alturas físicas en el planeta. (Instituto Nacional Geográfico del Perú IGN, 2016)

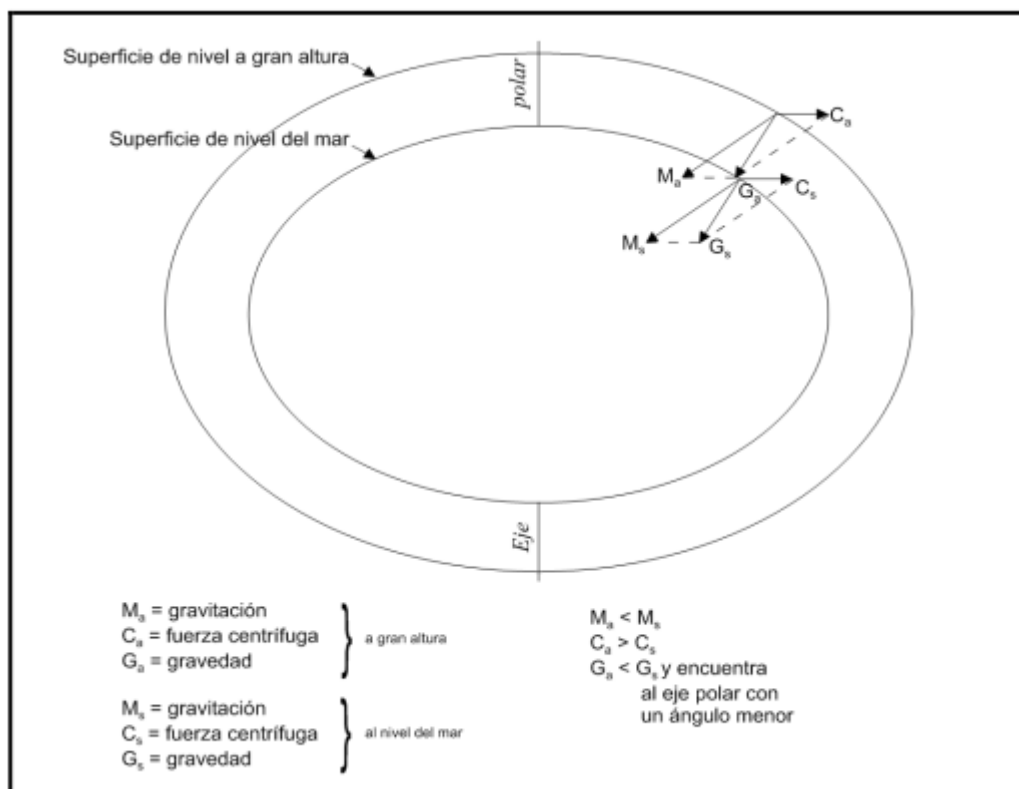


Figura N° 5: Comparación de los sistemas GPS, GLONASS, GALILEO, COMPAS Sobre la Órbita terrestre media

Fuente: (Cmglee, Geo Swan, 2016).

La dificultad en el cálculo del potencial de la gravedad terrestre está en el desconocimiento de la distribución de densidades en el interior del planeta, y para dar solución a esta limitante, se han implementado diversos métodos para la obtención del geoide, entre los más importantes se encuentran los métodos gravimétricos, modelos



geopotenciales del geoide, el método geométrico, entre otros. El método gravimétrico para la obtención del geoide se basa en el cálculo de la integral de Stokes mediante la medición de anomalías de la gravedad; los modelos geopotenciales del geoide por su parte combinan información satelital e información gravimétrica en superficie para desarrollar el potencial gravitacional en series de armónicos esféricos (Hofman & Helmut Moritz, 2005)

### **2.2.1 Método geométrico para la obtención del geoide**

El método geométrico para la obtención del geoide se basa en el cálculo de la ondulación geoidal en función de alturas elipsoidales y alturas niveladas. El conocimiento del comportamiento del geoide en sitios puntuales por medio de este método permite extender el cálculo del mismo a otros sitios en los cuales no se dispone de valores medidos de alturas elipsoidales y alturas niveladas; se incursiona de esta forma en el campo de la estimación de variables, existiendo distintos métodos de interpolación que pueden ser empleados con esta finalidad.

Al determinar la altura de un punto se debe tener en cuenta una superficie de referencia, ya que de acuerdo a como es obtenida se pueden distinguir alturas de tipo geométrico y alturas de tipo físico. El procedimiento que se emplea para conocer el valor de la altura se denomina nivelación, en donde las diferencias de nivel indican las variaciones topográficas del terreno.

### **2.2.2 Alturas niveladas**

Las alturas niveladas (H) son aquellas que se obtienen de las redes de nivelación de un país y tienen como referencia un dátum altimétrico relacionado con un mareógrafo en el cual se determina el nivel medio del mar (MSNMM) a lo largo de un tiempo que



permita considerar el conjunto de variaciones estacionales que pueda presentar el mismo (Figura N° 6). Una vez que se determina el origen del sistema de referencia vertical, se realiza un trabajo de nivelación hacia el interior del continente, con la finalidad de establecer puntos de control sobre la superficie topográfica (ST) para los cuales se fija un valor de altura a través del cálculo de desniveles ( $\Delta H_n$ ). Posteriormente son estos puntos los que se emplean como referencia para establecer valores de altura en nuevos sitios. Para la nivelación de las redes altimétricas nacionales se usa por lo general el método geométrico teniendo este un mejor desempeño que la nivelación trigonométrica en términos de precisiones alcanzadas.

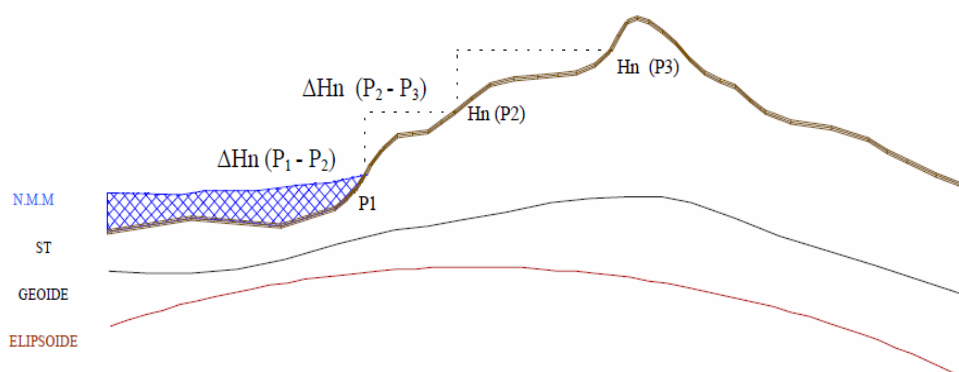


Figura N° 6: Alturas niveladas

Fuente (Carrión Sánchez, 2013)

### 2.2.3 Alturas elipsoidales

Las alturas elipsoidales son medidas sobre la normal al elipsoide desde la superficie del mismo hasta un punto sobre la superficie terrestre. Este tipo de alturas tienen un carácter geométrico y no pueden ser usadas en trabajos de ingeniería en los cuales es requisito realizar el cálculo de alturas considerando aspectos físicos en la determinación de los desniveles.

La ondulación geoidal ( $\eta$ ) es la distancia que existe entre un elipsoide de referencia y el geoide como superficie de referencia para las alturas, de esta forma el geoide queda

definido por los valores de altura que va tomando el mismo sobre el elipsoide de referencia.

En la Figura N° 7 se puede apreciar como en base al conocimiento de las alturas niveladas y las alturas elipsoidales, es posible llegar a calcular los valores de ondulación geoidal.




Figura N° 7: Superficies de referencia

De tal forma que se puede establecer la relación:  $\eta = h - H$

La ecuación anterior no se cumple en forma estricta, las alturas medidas con respecto al geoide ( $H$ ) y las medidas con respecto al elipsoide ( $h$ ) no son paralelas, por lo tanto existe un error intrínseco en el cálculo de por medio de esta fórmula. La altura  $H$  es medida sobre la normal al geoide, mientras la altura  $h$  es medida sobre la normal al elipsoide; por este motivo, entre estas dos normales se origina un ángulo denominado desviación de la vertical, a pesar de esta consideración este error puede ser despreciado para ciertos fines ya que no genera variaciones demasiado grandes en el cálculo de  $\eta$ .

#### 2.2.4 Nivelación

La nivelación es el mecanismo por medio del cual es posible obtener desniveles o diferencias de altura entre puntos distintos, existen varios métodos para realizarlo, uno de ellos es la nivelación geométrica, la cual utiliza visuales horizontales para medir

distancias verticales entre distintos puntos sobre el terreno, consiguiéndose con esto precisiones altas en el cálculo de desniveles por lo que este método es uno de los más empleados. La nivelación trigonométrica por su parte calcula distancias verticales entre puntos sobre el terreno valiéndose de relaciones trigonométricas y tomando como insumos la medición de distancias horizontales o inclinadas entre los puntos y el ángulo cenital que se forma entre los mismos. Dentro de la nivelación geométrica y trigonométrica existen variantes que se adaptan a las condiciones particulares en el trabajo de medición de desniveles y permiten a su vez eliminar o minimizar errores que se generan durante la ejecución del mismo.

Los datos usados como insumos para el entrenamiento de la red neuronal artificial en el presente trabajo poseen alturas niveladas por el método geométrico, garantizándose con esto un alto nivel de precisión.




Figura N° 8: Principio básico de la nivelación geométrica  
Fuente (Carrión Sánchez, 2013)

### 2.2.5 Sistema de alturas

Las alturas que proporcionan las redes de nivelación presentan algunas limitaciones, principalmente cuando se hace referencia al hecho de que los dátum verticales que se emplean para su medición están ligados a diferentes mareógrafos, la referencia que proporciona un mareógrafo está en relación directa con las condiciones particulares que

presenta el océano en el lugar donde este se encuentre; adicionalmente es importante considerar que la referencia de cada mareógrafo está determinada en una época particular; todo lo anteriormente señalado origina la no compatibilidad de las diferentes redes de nivelación al estar referidas a distintos mareógrafos, lo cual genera diferencias entre redes de nivelación de algunos centímetros e incluso metros.

Otro problema que por lo general presentan las redes de nivelación es que estas no consideran el no paralelismo de las superficies de nivel, es decir el efecto de la gravedad en la medición de desniveles. La medición de un desnivel estará siempre en relación con la dirección de la vertical del lugar en donde se realiza la nivelación, el efecto de esta condición se puede evidenciar al realizar un circuito de nivelación, al regresar al punto de partida la suma algebraica de todos los desniveles medidos no es igual a cero, este desajuste se conoce como error de cierre y es propio de los procesos de nivelación en los cuales no se considera el efecto gravimétrico.

Para eliminar el error de cierre en la nivelación, se propone el cálculo de variaciones de potenciales de la gravedad (Hofman & Helmut Moritz, 2005) en vez de realizar únicamente determinación de desniveles.

### **2.2.6 Sistema de alturas en el Perú**

El dátum vertical en el Perú, tiene su origen en el mareógrafo de La Punta – Callao, y mediante nivelación geométrica de alta precisión se distribuyó a nivel nacional mediante líneas de nivelación que se encuentran distribuidos dentro del ámbito del territorio nacional a lo largo de las vías de comunicación terrestre, los mismos que constituyen bienes del Estado.

Las alturas niveladas con que cuenta la red de nivelación nacional, presentan discrepancias con respecto a alturas determinadas mediante redes de nivelación de otros

países, explicándose este hecho por estar referida la red de nivelación nacional a un datum local, además es necesario señalar que en el Perú aún no se encuentra establecido un sistema de alturas que esté referido a una superficie equipotencial, en un futuro el sistema de referencia vertical en el país estará orientado al cálculo de números geopotenciales, con lo cual se conseguiría el establecimiento de un sistema de alturas reales.

Así mismo en el continente sudamericano, existen tantos sistemas de alturas, como mareógrafos de referencia, como una multiplicidad de niveles de referencia.

La superficie de referencia (en mareógrafos) de los sistemas de alturas existentes no está sobre el mismo nivel, los cuales difiere temporalmente (cambios en el tiempo) por mareas, presión de la atmósfera, temperatura permanentemente (por la topografía del mar), por corrientes (p.ej. Humboldt), densidad del agua (salinidad, temperatura), entre otros.

Las redes verticales son ajustadas línea por línea o circuito por circuito. Si un punto forma parte de dos líneas de nivelación ajustadas independientemente, tiene valores de altura diferentes.

En consecuencia, se tienen inconvenientes de los sistemas de alturas existentes, tales como:

Diferentes mareógrafos (inconsistencias en el rango de 2 m)

Nivelación geométrica sin reducción gravimétrica (o con diferentes reducciones, incertidumbres hasta de 1,20 m)

Diferentes épocas de medición (movimientos verticales asumidos como errores de observación, magnitudes hasta varios decímetros)

Estáticos (omisión de las variaciones temporales)

El sistema de referencia geométrico (ITRS/ITRF, SIRGAS y sus densificaciones nacionales) es consistente en un orden de precisión de 10-9.

Los sistemas de alturas (físicas) existentes son compatibles entre sí solamente en el orden 10-6.

La precisión relativa de las alturas niveladas es muy alta (en el orden de milímetros), pero dicha precisión se desmejora al no incluir las correcciones gravimétricas en los desniveles medidos.

La precisión de las alturas existentes se mejora considerablemente, si las redes verticales son reajustadas incluyendo las correcciones gravimétricas (o en términos de números geopotenciales). Sin embargo, esas alturas continúan siendo consistentes solamente entre ellas porque se refieren a un mareógrafo, cuya posición respecto al geoide no es conocida. En consecuencia, los sistemas de alturas existentes no satisfacen la ecuación  $h = H + N$  (relación de las alturas elipsoidales [h] con las alturas físicas [H, ortométricas o normales] y la superficie de referencia correspondiente [N, el geoide o el cuasi geoide]). Es decir, no permiten la obtención de alturas físicas a partir de posicionamiento GNSS y modelos geoidales.

Mientras que SIRGAS permite el intercambio preciso [en milímetros] de información geodésica geométrica (XYZ) en proyectos supranacionales, los sistemas de alturas existentes presentan inconsistencias hasta de 2 metros.

Los sistemas de alturas existentes en América Latina resultan obsoletos ante la precisión ofrecida por las técnicas geodésicas modernas, especialmente las apoyadas en el posicionamiento y la navegación satelital. Si se quiere aprovechar al máximo este tipo de tecnologías en nuestro país, es necesario modernizar los sistemas de alturas de manera similar como se ha hecho con el sistema geocéntrico de referencia SIRGAS.



Figura N° 9: Red Nacional de nivelación de alta precisión (NAP)

Fuente: (Instituto Nacional Geográfico del Perú IGN, 2016)

## 2.3 FUNDAMENTOS DEL SISTEMA GPS Y APLICACIONES EN LA TOPOGRAFÍA

### 2.3.1 Fundamento sobre el sistema

El Sistema de Posicionamiento Global (GPS) es un sistema de localización, diseñado por el Departamento de Defensa de los Estados Unidos con fines militares para proporcionar estimaciones precisas de posición, velocidad y tiempo; operativo desde 1995 utiliza conjuntamente una red de ordenadores y una constelación de 24 satélites para determinar por triangulación, la altitud, longitud y latitud de cualquier punto u objeto en la superficie terrestre.

En el ámbito civil y alegando razones de seguridad sólo se permite el uso de un subconjunto degradado de señales GPS. Sin embargo, la comunidad civil ha encontrado alternativas para obtener una excelente precisión en la localización mediante las

denominadas técnicas diferenciales. Gracias a ellas las aplicaciones civiles han experimentado un gran crecimiento y actualmente existen más de setenta fabricantes de receptores GPS (Ayala Ramírez & Hasbun Bardales, 2012).

### 2.3.2 Método Diferencial

Las señales de los satélites son recibidas simultáneamente por dos receptores. Con este método se anulan hasta un cierto grado errores inevitables como la imprecisión de la órbita del satélite y se obtiene con ello una mayor precisión que con la determinación de un punto aislado. Se utiliza aquí el método de medición de fase que da una mayor precisión que el de la medida de la pseudodistancia. Evidentemente es necesario restituir en un ordenador los puntos medidos en distintas estación (Peñañiel & Zayas , 2001).

Los errores que se eliminan utilizando el método diferencial son los siguientes:

Disponibilidad selectiva (SA)

Retardo ionosférico.

Retardo troposférico.

Error en las efemérides.

Error reloj satélite.




Figura N° 10: Método Diferencial

Fuente: Peñañiel Javier & Zayas Jorge, 2001.



### 2.3.2.1 Mascara de Elevación

Es el ángulo de elevación mínimo que tendrán los satélites para que recibamos señal de estos. Este ángulo es configurable y se considera como el mínimo ideal de  $15^\circ$  de elevación, ya que por debajo de este ángulo, la señal recibida de los satélites, está muy influenciada por la refracción atmosférica (Ayala Ramírez & Hasbun Bardales, 2012).




Figura N° 11: Mascara de Elevación

Fuente: (Peñañiel & Zayas , 2001).

## 2.3.3 Posicionamiento GPS métodos y aplicaciones

### 2.3.3.1 Posicionamiento absoluto

Decimos que un posicionamiento es absoluto, cuando se calcula la posición del punto utilizando las medidas de pseudodistancia ya sea procedentes del código C/A, o código P. Dependiendo del código que utilicemos y de la disponibilidad selectiva obtendremos una precisión que variará de 3 a 5 m. en tiempo real. Este tipo de posicionamiento es utilizado por los equipos llamados navegadores (Peñañiel & Zayas , 2001).

### 2.3.3.2 Posicionamiento diferencial

#### 2.3.3.2.1 Método estático

Llamamos posicionamiento diferencial cuando están involucrados dos o más instrumentos GPS, con el fin de eliminar los errores propios del sistema GPS, calculando los incrementos de coordenadas desde el equipo de referencia al móvil.

Estático.- Este método se utiliza para distancias largas (por lo general mayores de 20 Km.) y la más alta precisión. Es la medición clásica de líneas bases.

Consiste en estacionar dos receptores o más receptores en los puntos los cuales queremos conocer sus coordenadas, almacenar datos y calcular las coordenadas en tiempo diferido. En este tipo de posicionamiento se obtienen soluciones tan redundantes como deseemos, tan solo deberemos prolongar la observación.

Estático Rápido.- Las distancias máximas que pueden existir entre la referencia y el móvil es de 20 Km.

Los tiempos breves de observación posibilitan una precisión de 5 a 10 mm.  $\pm$  1 ppm, los tiempos de observación son de 5 a 10 minutos para distancias inferiores a 5 Km (Peñañiel & Zayas , 2001).




Figura N° 12: Línea Base

Fuente: (Ayala Ramírez & Hasbun Bardales, 2012).

### 2.3.3.2.2 Método Cinemático

**Cinemático Post Procesado (PPK).**- El método cinemático mide la posición relativa de dos puntos levantados en un intervalo de tiempo pre-definido por el usuario. Para un posterior procesamiento (Ayala Ramírez & Hasbun Bardales, 2012).

**Cinemático en Tiempo Real (RTK).**- Esta es la última innovación en las técnicas de medida GPS. Consiste en obtener coordenadas en tiempo real en el sistema de referencia adoptado previamente.

En la actualidad, la topografía con métodos de medición GPS está cada vez más arraigada y comienza a sustituir a los métodos clásicos de medición, como por ejemplo redes locales, triangulaciones apoyos fotogramétricos, bases de replanteo, etc. Todo esto ha sido gracias al desarrollo de técnicas introducidas en los últimos cinco años y explicadas anteriormente, Estático Rápido, Stop & Go, PPK, etc. Debido a que la constelación se ha completado con 24 satélites es posible llevar a cabo posicionamientos en los que las condiciones de cobertura son más estrictas, de esta manera tenemos una cobertura de 24 horas al día en cualquier parte del mundo.

Todos los avances tecnológicos efectuados en las técnicas de medición GPS se dirigen hacia estar el menor tiempo posible en la toma del punto y tener el resultado en el propio campo. Hasta ahora este tipo de trabajo quedaba reservado a los métodos clásicos (Estaciones Totales). Sin embargo mediante el Tiempo Real en el GPS, podremos utilizar éste de manera similar a una Estación Total, obtención de coordenadas al instante. Esto quiere decir que podremos utilizar nuestro equipo GPS para métodos de levantamiento y replanteo (Ayala Ramírez & Hasbun Bardales, 2012).

### 2.3.4 Receptor de Formato Independiente de Intercambio (RINEX)

La necesidad de combinar distintos tipos de receptores de distintas casas comerciales, de distintas versiones, en el mismo proyecto, y calcular los datos con un mismo programa se convierte en una de las primeras necesidades.

El formato RINEX satisface esta necesidad de intercambio de información registrada por equipos de posicionamiento por diferentes satélites, ya sean GPS, TRANSIT, GLONASS o combinados.

A menudo el topógrafo, que quiere combinar los datos de los diferentes tipos de receptores, tiene que estar familiarizado con ciertas características; tiene que conocer la amplitud y restricciones de los procesos posteriores del programa de cálculo que se utiliza y finalmente, tiene que tener la suficiente experiencia en los cálculos de GPS para determinar los resultados finales.

Los ficheros RINEX se denominan por convención de la siguiente forma:

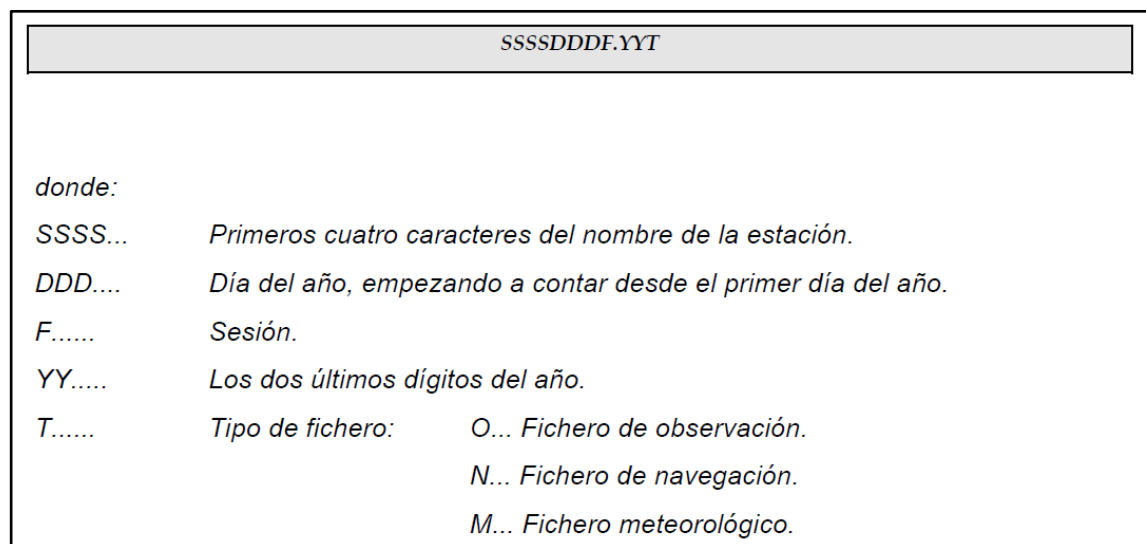


Figura N° 13: Formato de denominación de los ficheros RINEX

Fuente: (Ayala Ramírez & Hasbun Bardales, 2012).

## 2.4 RED NEURONAL ARTIFICIAL (RNA)

El funcionamiento del cerebro animal, desde siempre ha constituido un enigma y ha sido objeto de innumerables estudios e investigaciones; la capacidad del cerebro en las tareas de resolución de problemas involucra una serie de funciones internas que todavía no son comprendidas en su totalidad.

La aparición de los sistemas informáticos permitió que muchas de las tareas con las que se enfrentaba a diario el ser humano sean realizadas con mayor agilidad y eficiencia, sin embargo este tipo de sistemas presenta una limitación, la resolución de problemas requiere un tratamiento algorítmico, cuando el problema a solucionar no se acopla a estas características, es necesario que se de otro tipo de tratamiento al procesamiento de la información que participa en el asunto al que se quiera dar solución.

La Inteligencia Artificial es la disciplina que estudia los mecanismos mediante los cuales una máquina puede emular el funcionamiento del cerebro humano, con el fin de dar solución a problemas que los sistemas informáticos clásicos no pueden hacerlo. Constituye un intento por adaptar las cualidades cognoscitivas del ser humano al campo informático, de tal forma que se pueda conjugar la gran capacidad de resolución de problemas del cerebro con la agilidad de los procesos informáticos. Se puede afirmar que aquellos problemas que no admiten una resolución algorítmica, nos conducen a una solución que se basa en la capacidad de memorizar y asociar hechos, es decir que use como insumo fundamental la experiencia.

En este contexto, las redes neuronales artificiales como parte constitutiva de las técnicas de inteligencia artificial, tienen como objetivo el reproducir la capacidad de aprendizaje del cerebro humano mediante el uso de máquinas, simulando en la medida de lo posible la estructura y funcionamiento de las redes neuronales biológicas.

Cuando la red de neuronas artificial trata de emular a los sistemas neuronales biológicos, nos referimos al modelo de red neuronal artificial de tipo biológico, por otra parte si la red neuronal artificial adopta una estructura dependiendo de las necesidades del problema que intenta resolver, estamos hablando de las redes neuronales artificiales del tipo dirigido a aplicación, es decir este modelo no guarda similitud en su arquitectura con los sistemas biológicos.

Una red neuronal artificial, es un conjunto de unidades procesadoras que reciben el nombre de neuronas y se encuentran interconectadas entre sí para permitir el intercambio y procesamiento de información.

#### **2.4.1 Historia de la Redes Neuronales Artificiales**

**1936:** Alang Turing.- Empieza a estudiar al cerebro relacionándolo con la computación.

**1943:** Warren Mc Culloch y Walter Pitts.- desde el punto del campo de estudio de la neurofisiología y la matemática fueron los primeros teóricos en aportar conocimientos en cuanto se refiere al funcionamiento de las neuronas, y elaboraron el primer modelo matemático de unas redes de neuronas artificiales mediante circuitos eléctricos. El modelo se basa en el principio de que las neuronas operan en base a impulsos binarios.

**1949:** Donald Hebb.- explica los procesos de aprendizaje, desarrollando un proceso matemático. Proporciona así el fundamento de la mayoría de las funciones de aprendizaje que participan en una red neuronal. Hebb planteó que el aprendizaje sucedía cuando en la neurona se producían ciertos cambios. Este paradigma de los procesos de aprendizaje se llama aprendizaje Hebbiano.

**1950:** Karl Lashley.- a través de varios ensayos, concluyó que la información no era almacena en forma centralizada sino que se distribuía encima del cerebro.

**1951:** Marvin Minsky.- basándose en los resultados obtenidos previamente por Mc Culloch y Pitts, Minsky junto con Edmons diseñan una máquina con 40 neuronas cuyas conexiones contaban con la capacidad de ajustarse, la máquina estaba construida con tubos, motores y relés.

Consiguió con esto modelar el comportamiento de una rata buscando alimento en un laberinto.

**1656:** Albert Uttley.- desarrolla una máquina teórica compuesta por separadores lineales que ajustaban sus parámetros de entrada usando la medida de entropía de Shannon.

**1957:** Frank Rosenblatt.- añade aprendizaje al modelo neuronal de Mac Culloch y Pitts, este modelo dotado de aprendizaje tomó el nombre de PERCEPTRON. En primer lugar elaboró un modelo de dos niveles, en el cual se ajustaban las conexiones entre la capa de salida y la capa de entrada, en lo posterior intentó desarrollar un modelo con tres niveles, sin embargo no logró encontrar un mecanismo matemático robusto para el ajuste de las conexiones o pesos que se encontraban entre la capa de entrada y la oculta.

**1961:** Steinbuch.- fue de los primeros investigadores en desarrollar métodos de codificación de información en redes neuronales.

**1964:** Stephen Grossberg.- es reconocido como el más influyente de los investigadores en redes neuronales, realizó estudios sobre el procesamiento humano de la información basándose en fundamentos psicológicos y biológicos.

Para finales de la década de los 60 y en los años 70 y 80 se generan nuevas investigaciones en el campo de las redes neuronales artificiales, entre los principales investigadores que aportaron con sus trabajos científicos se pueden mencionar: Shun-ichi Amari, James Anderson, Higgins, Kunihiko Fukushima, Harry Klopff, Teuvo Kohonen, Leon Cooper, Charles Elbaum, Terence Sejnowski, McClelland, Rumelhart,

Jerome Feldman, Dana Ballard, Robert Hecht, John Hopfield, Bart Kosko. (Isasi Viñueta Pedro, 2004)

#### **2.4.2 Neurona biológica**

La neurona o célula nerviosa es el elemento estructural del sistema de comunicación neuronal, se estima que el cerebro humano de un adulto posee aproximadamente unas 100 mil millones de neuronas y la transmisión de la información entre estas se realiza por medio de señales químicas que se originan de los productos de secreción de las neuronas.

La interconexión neuronal se realiza por medio de elementos receptores conocidos como dendritas y de elementos transmisores llamados axones, las dendritas reciben la información que proviene de otras neuronas para que luego de ser transmitida al cuerpo neuronal pueda ser procesada y posteriormente enviada hacia otras neuronas por medio de su axón, se estima que una neurona puede tener de 10 mil a 100 mil conexiones sinápticas por medio de sus dendritas y un número similar de conexiones entre su axón y dendritas de células vecinas, el elevado número de conexiones en las que participa cada célula neuronal determina el potencial cerebral.

El axón presenta unas ramificaciones en su extremo que está en relación con otras neuronas o con células efectoras sin llegar a tener contacto con ellas, estas ramificaciones del axón reciben el nombre de botones terminales y el espacio existente entre estos y las neuronas con las cuales se relacionan se conocen como sinapsis, es decir estos espacios constituyen el elemento de unión entre axones y dendritas y tienen la propiedad de contener determinadas concentraciones de iones de sodio y potasio en un medio líquido.



La transmisión de información mediante la liberación de sustancias llamadas neurotransmisores es un proceso químico y el efecto que produce sobre la neurona receptora es elevar o disminuir su potencial eléctrico, los iones provocan que el espacio intersináptico adquiera ciertas propiedades de conductividad que determinan si el impulso eléctrico es activado o impedido en cierto grado, las sinapsis cumplen la función de potenciadores o inhibidores de la señal que proviene de los axones, actuando como aislantes o amplificadores.

Si el potencial eléctrico alcanza un umbral se enviará un pulso por el axón, es decir la neurona se dispara y dicho pulso alcanzará a otras células por medio de sus conexiones. Es importante destacar que cada vez que una sinapsis es activada y encuentra activado o consigue activar otra neurona, la cantidad de neurotransmisores liberados aumenta la próxima vez que la neurona sea activada, este proceso es conocido como facilitación, la intensidad de una conexión sináptica entre dos neuronas aumenta cuando estas son excitadas simultáneamente, este principio inspiró la Ley de Hebb (Hebb, 1949) que es básica en muchos algoritmos de aprendizaje de redes neuronales artificiales.

Existen también neuronas que se encargan de recibir estímulos del exterior o el interior del organismo, y otras que conducen la información elaborada en forma de órdenes hacia los efectores. (Isasi Viñueta Pedro, 2004)




Figura N°14: Estructura de una neurona Biológica

Las concentraciones de iones sodio y potasio que existen dentro y fuera de las células, generan un punto de equilibrio de -85 milivoltios, negativo en el interior de la célula con respecto al exterior, cualquier perturbación en la membrana de la neurona provoca una serie de modificaciones que desaparecen rápidamente, durante ese pequeño periodo el potencial se torna positivo. Esta onda de variación de tensión se llama potencial de acción. Los estímulos que reciben las neuronas tienen como efecto la destrucción de las propiedades dieléctricas de su membrana, la permeabilidad al sodio y al potasio aumenta, dándose origen a la difusión de estos iones a través de la membrana, después de un tiempo el estado neuronal vuelve a la normalidad por medio de mecanismos de transporte activo que es el transporte de moléculas a través de la membrana celular contra el gradiente de concentración y con el uso de energía; a esta fase se la conoce como repolarización, posteriormente durante un tiempo, la membrana no es sensible a otras perturbaciones y se llama período refractario, en este período se sucede la transmisión de pulsos eléctricos al axón; el potencial de acción tiene por objeto la liberación de neurotransmisores en la sinapsis con el objeto de producir la

perturbación de las membranas de otras neuronas y de esta forma el fenómeno adquiere continuidad.

### 2.4.3 Neurona artificial

Las neuronas artificiales, células o autómatas son capaces de cambiar de estado dependiendo de las entradas que tengan y de las conexiones sinápticas asociadas, este estado se conoce como nivel de activación y significa que ante nuevas entradas la red podrá presentar estados de activación diferentes. Las neuronas cuentan con una función que les hace posible cambiar de estado de activación a partir de las señales que reciben, esta función se conoce como función de activación o función de transición de estado, el nivel de activación de una célula depende de las entradas que reciba y de los valores de las conexiones sinápticas, pero no depende de estados de activación anteriores.

Para determinar el nivel de activación de una neurona ( $y$ ), es necesario en primer lugar calcular la entrada total a la célula para posteriormente evaluar este valor por medio de la función de transferencia ( $f$ ), la entrada total a la neurona ( $\Sigma$ ) es equivalente a la suma ponderada de las entradas por sus respectivos pesos sinápticos ( $\omega$ )

La entrada total a la célula puede definirse por la ecuación 1.1:

$$\Sigma = x_1 * \omega_1 + x_2 * \omega_2 + x_3 * \omega_3 + \dots + x_n * \omega_n \quad (1.1)$$

Y en forma vectorial:

$$\Sigma = X^T * \omega \quad (1.2)$$

En donde:

$X^T$  = vector de entradas a la neurona

$\omega$  = vector de pesos sinápticos

Con lo cual se puede calcular la salida de la neurona (ecuación 1.3) luego de aplicar a  $\Sigma$  una función de transferencia  $f$ .

$$y = f(\Sigma) \quad (1.3)$$




Figura N° 15: Modelo de Neurona Artificial

Fuente: (Carrion Sanchez, 2013)

La función de activación o función de transferencia ( $f$ ) produce la salida ( $y$ ) de la neurona al evaluar el valor de  $\Sigma$  (Figura N° 15), existen distintas funciones de transferencia y dependiendo de cuál se utilice se define el modelo de neurona artificial que se requiera, en general puede ser cualquier función y su elección dependerá del tipo de fenómeno que la neurona va a aprender.

Las funciones de transferencia básicas son la función lineal (ecuación 1.4) que utiliza una constante que opera como múltiplo de  $\Sigma$  para generar la salida de la neurona ( $y$ ) y la función umbral (1.5) que compara a  $\Sigma$  con un valor umbral y asigna valores

binarios a la salida de la neurona mediante funciones lógicas mayor que y menor que (Haykin, 2001).

**Función lineal:**

$$f(\Sigma) = c \cdot \Sigma = y \quad (1.4)$$

Dónde:

$c$  = es una constante

**Función umbral:**

$$\left. \begin{array}{l} f(\Sigma) = 0 \text{ Si } \Sigma < \textcircled{\text{II}} \\ f(\Sigma) = 1 \text{ Si } \Sigma \geq \textcircled{\text{II}} \end{array} \right\} \quad (1.5)$$

Dónde:

$\textcircled{\text{II}}$  Es un umbral constante

#### 2.4.4 Red neuronal artificial

El concepto de red neuronal artificial se fundamenta en el conocimiento que se tiene sobre la estructura y funcionamiento de las redes neuronales biológicas, el captar información a manera de estímulos, procesarla y transmitirla en un sistema paralelo de elementos constitutivos llamados neuronas, son características que emula la red neuronal artificial de su par biológico, sin embargo existen también algunas particularidades que diferencian a las redes de neuronas artificiales de los sistemas biológicos, principalmente en la complejidad de las sinapsis, en los puntos de interconexión interneuronal, y por el hecho de que los sistemas biológicos tienen miles de componentes y de procesos activos de propagación de impulsos electroquímicos,

mientras que en los sistemas artificiales los puntos de conexión son bastante simples y las entradas son procesadas mediante una suma ponderada que luego es transferida a una función umbral.

Además en los sistemas biológicos la información se transporta por medio de impulsos electroquímicos que llegan a las neuronas en cualquier momento, es decir su funcionamiento es asíncrono, con lo cual se ejecuta la reconfiguración de la red en cualquier instante, mientras que en los sistemas artificiales la actualización de los parámetros de la red se produce en forma periódica y es muy común que se lo haga en forma conjunta.

Dentro de las diferencias existentes entre las redes de neuronas artificiales y las biológicas es importante destacar que estas últimas son capaces de aprender en un período más corto y con una menor cantidad de patrones presentados, al contrario las redes neuronales artificiales precisan de ser provistas de una gran cantidad de patrones de entrenamiento para poder llegar a un nivel de aprendizaje en el que se consiga un poder de generalización aceptable. Por lo tanto el tiempo invertido en el aprendizaje que realiza la red es considerablemente superior al que emplearía una red de tipo biológico. En cuanto se refiere a la arquitectura de las redes neuronales, se puede afirmar que los sistemas artificiales presentan una arquitectura sencilla que comprende un conjunto de capas de neuronas interconectadas, mientras en los sistemas biológicos las redes neuronales se conforman por niveles (córtex, circunvoluciones, cerebelo, hipocampo), que constituyen una densa malla de conexiones con una estructura poco definida y que puede variar en el tiempo (Isasi Viñueta Pedro, 2004).

En cuanto a su funcionamiento, una red de tipo artificial se enfoca en dar solución a un problema en particular para lo cual es entrenada, en tanto las redes de neuronas

biológicas son capaces de aprender un número considerable de tareas en forma simultánea.

Como una ventaja de las redes neuronales artificiales en comparación con las biológicas, se tiene que en estas últimas no es posible cuantificar un valor o medida precisa en los impulsos electroquímicos, lo cual sí es posible realizar en las redes artificiales, determinando de forma más o menos precisa los valores que se transfieren de un elemento de procesamiento a otro (Isasi Viñueta Pedro, 2004).

Aunque existen marcadas diferencias entre los sistemas artificiales y los naturales, las redes de neuronas artificiales han logrado simular de sus pares biológicas la representación y procesamiento distribuido de la información, lo que les permite contar con tolerancia a fallos, entendiéndose esto como la capacidad para seguir funcionando pese a que se haya dañado uno o más de sus elementos constitutivos.

El empleo de redes de neuronas artificiales para la solución de problemas puede presentar ciertas limitaciones, principalmente vinculadas al tiempo de entrenamiento y a su diseño, el número de veces que es necesario mostrar el conjunto de datos de entrenamiento a la red para que se realice el aprendizaje no se conoce a priori, por tal motivo es imposible saber el tiempo que será necesario hasta que la red alcance una capacidad de generalización aceptable, esto puede convertirse en un inconveniente importante si se desea solucionar un problema de forma inmediata y puede tornarse crítico si consideramos que el diseño de la red neuronal se genera

Conforme se desarrolla un procedimiento de prueba y error, es decir el diseño óptimo de la red se determina en función del desempeño de la misma durante un período de pruebas que de igual forma representa una gran cantidad de tiempo invertido.

Entre las ventajas del empleo de redes neuronales artificiales para resolver problemas, se destacan las siguientes (Isasi Viñueta Pedro, 2004):

***Aprendizaje adaptativo:*** Resolución de problemas luego de haber pasado por un proceso de aprendizaje en el cual se adquiere experiencia. No es necesario diseñar algoritmos y modelos de distribución de probabilidad.

***Auto-organización:*** Mediante una etapa de aprendizaje, la red tiene la capacidad de organizar y representar la información que recibe. La auto-organización favorece a la capacidad de generalización, por medio de la cual la red puede generar salidas ante la presentación de entradas que no se han mostrado durante el período de entrenamiento.

***Tolerancia a fallos:*** Las capacidades adquiridas por la red se mantienen, incluso existiendo una degradación de su estructura por el daño de alguno o algunos de sus elementos constitutivos. Las redes neuronales artificiales también poseen tolerancia a fallos con respecto a los datos, siendo capaces de aprender a reconocer patrones aunque estos tengan ruido, estén incompletos o distorsionados. La tolerancia a fallos se logra por el almacenamiento de la información en forma no localizada, estando ésta distribuida en las conexiones entre las neuronas, existiendo así cierta redundancia en la información que puede ser utilizada cuando un número de neuronas sufre un daño.

***Operación en tiempo real:*** La red neuronal puede hacer cálculos en paralelo, esto se puede lograr mediante el uso de hardware apropiado. La necesidad de modificar los pesos sinápticos en las conexiones es mínima.

#### **2.4.5 Estructura de una red neuronal artificial**

Una red de neuronas artificial se estructura por niveles o capas interconectadas, por medio de las cuales se transfiere la información, en la capa de entrada se recibe la información proveniente del exterior y sin efectuar ningún procesamiento sobre ella se transfiere a la siguiente capa de la red por medio de las interconexiones neuronales, las



cuales poseen un valor sináptico o peso que opera sobre las entradas de la red antes de que estas sean transferidas a las neuronas de la capa oculta.

La información que reciben las neuronas en cada capa de la red, es evaluada por una función de transferencia antes de ser transferida hacia las neuronas de la siguiente capa o nivel. Finalmente la información que procede de las capas ocultas de la red se transfiere hacia la capa de salida, para que al igual que en las capas ocultas, la información sea evaluada por medio de una función de transferencia que genera la salida definitiva de la red. Una red neuronal artificial puede tener una o varias capas ocultas o intermedias, dependiendo del problema abordado.

La forma en que las neuronas se conectan entre si dentro de la red se conoce como arquitectura de la red y se define con el objetivo de que esta tenga la capacidad de aprender a través de los ejemplos que son introducidos durante la etapa de entrenamiento y de representar el fenómeno para el cual fue diseñada. Los valores de las conexiones interneuronales son establecidos durante el período de aprendizaje, haciendo modificaciones reiteradas de los mismos hasta que la red ha asimilado la información que ha recibido durante el entrenamiento, cuando esto sucede, la red está lista para usarse en la representación de otros patrones no presentes en el conjunto de entrenamiento.

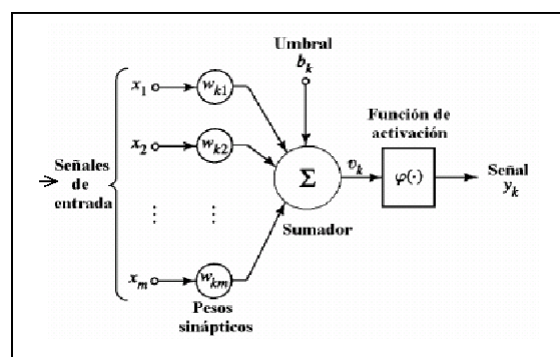


Figura N° 16: Estructura de una red neuronal de tres capas

Fuente: (Haykin, 2001).

#### 2.4.6 Aprendizaje de la red neuronal artificial

El aprendizaje de la red sucede durante el entrenamiento, es decir la red aprende a reconocer patrones relacionándolos con sus respectivas salidas, los pesos sinápticos son ajustados en varias iteraciones mientras se ingresan las entradas del conjunto de entrenamiento y se comparan sus salidas con las salidas que genera la red. Un algoritmo de aprendizaje permite ajustar los pesos sinápticos en función de las diferencias existentes entre las salidas reales o targets y las salidas calculadas por la red, se dispone de algunos algoritmos válidos para realizar el entrenamiento y su elección depende del tipo de problema que la red debe aprender a solucionar.

Los ejemplos del conjunto de aprendizaje deben cumplir con ciertas características para que su desempeño sea apropiado y proporcionen a la red la información suficiente para que esta pueda representar el problema de forma satisfactoria. En primer lugar los datos deben ser representativos, esto quiere decir, que es conveniente presentar a la red ejemplos diversos y equiparables en proporción, es decir el conjunto de entrenamiento deberá contener la mayor parte de tipos de patrones que pueda abarcar el fenómeno, si solo se muestran ejemplos de un tipo, la red se especializará en la representación de ese tipo de patrón y producirá salidas sesgadas; por otra parte el conjunto de datos de entrenamiento debe ser significativo, para que la red logre adaptar los pesos de sus conexiones hasta generar salidas adecuadas, requiere contar con un número apropiado de ejemplos durante la etapa de aprendizaje (Basogain Olabe, 2008).

Existen varios criterios para determinar la finalización del entrenamiento de la red, esto se puede hacer fijando un número de ciclos o repeticiones en las cuales se introducirá todo el conjunto de entrenamiento; una vez que se cumpla con dicho número se detiene el proceso de aprendizaje.

Otra forma de establecer cuándo se debe detener el entrenamiento es determinando un valor que será comparado con el error que genera la red, mientras el error sea mayor que dicho valor, el proceso de aprendizaje continua y en caso contrario se detiene; finalmente existe otro mecanismo mediante el cual se puede condicionar la finalización del entrenamiento y consiste en detener el proceso cuando la modificación de los pesos sea irrelevante. En los dos últimos casos es necesario acompañar al criterio de finalización de otro complementario, ya que es posible que la condición establecida en el primer criterio nunca llegue a cumplirse (Isasi Viñueta Pedro, 2004).

## **2.4.7 Tipos de esquemas de aprendizaje**

### ***2.4.7.1 Aprendizaje supervisado***

En este tipo de esquema de aprendizaje, el conjunto de entrenamiento consta de dos componentes, las entradas a la red que representan las variables que definen el problema y sus salidas asociadas, estas salidas son útiles para calcular las diferencias con las salidas que genera la red, con la finalidad de ajustar los pesos en función de estas diferencias, el algoritmo de aprendizaje utiliza estos errores de la red para calcular nuevos pesos sinápticos que aproximen en mejor forma los targets o salidas deseadas. La modificación en los pesos será proporcional a los errores que genere la red, conforme las salidas de la red se aproximen a los targets, la variación en los pesos sinápticos será cada vez menor. Al aprendizaje supervisado se lo conoce también como "aprendizaje con profesor".

### ***2.4.7.2 Aprendizaje no supervisado***

En el aprendizaje no supervisado, la modificación de los pesos sinápticos se realiza sin contar con un "profesor", esto significa que el conjunto de entrenamiento está compuesto únicamente por las entradas que definen el problema y no se muestra a la red

las salidas deseadas (targets) que se corresponden con dichas entradas, la red neuronal utiliza para su entrenamiento únicamente la información que proviene de los ejemplos de entrada y mediante un algoritmo de aprendizaje tiene la capacidad de generar asociaciones con los ejemplos que se le han introducido. Es decir determina grados de familiaridad o similitud entre los mismos basándose en características como rasgos significativos, regularidades o redundancias, la modificación de los pesos se hará en base a información interna que posee la red.

#### ***2.4.7.3 Aprendizaje por refuerzo***

Este tipo de aprendizaje garantiza que la red neuronal artificial logre una buena capacidad de generalización, una vez se ha entrenado a la red con un método supervisado, los errores registrados durante la etapa de aprendizaje son calculados con respecto al conjunto de entrenamiento y estos presentarán discrepancias con los errores que resultarán cuando la red opere con entradas que no participaron en el aprendizaje. El obtener un error pequeño durante la etapa de entrenamiento, no implica que la capacidad de generalización de la red esté garantizada, para solucionar este inconveniente se utiliza los esquemas de aprendizaje por refuerzo, consiste en dividir al conjunto de datos que se dispone en dos subconjuntos, uno de entrenamiento y otro de validación, el primero sirve para que la red ajuste sus pesos de la misma forma que se hace en el aprendizaje supervisado, pero el error cometido por la red es calculado con los datos del conjunto de validación, siendo importante el hecho de que estos no participan en el ajuste de los parámetros, de esta manera se consigue una medida más confiable del poder de generalización de la red (Isasi Viñueta Pedro, 2004).

### 2.4.8 Perceptrón

El Perceptrón es un modelo de red neuronal que fue diseñado para realizar clasificación de patrones, los parámetros que constituyen las conexiones sinápticas de la red definen superficies discriminantes que sirven para clasificar conjuntos de patrones. El entrenamiento de una red tipo Perceptrón se realiza presentando ejemplos que contienen los diferentes tipos de patrones que se requiera clasificar (Basogain, 2008).

Una red de neuronas artificial de tipo Perceptrón (Figura N° 17) está constituida por entradas y neuronas de salida, el número de células se determina dependiendo del tipo de problema que se desea resolver y todas las entradas están conectadas con cada una de las neuronas de salida.

Las neuronas de la capa de salida utilizan una función de transferencia tipo umbral o escalón que genera salidas binarias que resultan de determinar si la activación de la célula ( $\Sigma$ ) supera o no en valor numérico al umbral.

$$\left\{ \begin{array}{l} y = 1 \text{ si } \sum_{i=1}^n X_i * \omega_i > \Theta \\ y = -1 \text{ en caso contrario} \end{array} \right. \quad (1.6)$$

Siendo "y" la salida de la neurona.

Si se incluye al valor umbral como otro de los parámetros de la red y se vincula a este peso sináptico con una entrada constante igual a 1, es posible que el umbral se fije en cero y las ecuaciones anteriormente señaladas cambiarían a la forma:

$$\left\{ \begin{array}{l} y = 1 \text{ si } \left( \sum_{i=1}^n X_i * \omega_i - \Theta \right) > 0 \\ y = -1 \text{ en caso contrario} \end{array} \right. \quad (1.7)$$

El umbral o bias pasa a formar parte del operador sumatoria a manera de un peso sináptico asociado a una pseudo entrada ( $X_0$ ) a la neurona con un valor constante de 1.

Recordando que el objetivo del perceptrón es clasificar patrones, la salida binaria que tienen este tipo de redes neuronales se adapta a los requerimientos de la misma, es decir, si la salida es 1 se interpreta que la entrada que la generó pertenece a la clase “A” y si la salida es -1 se concluye que el patrón que generó esta salida se agrupa dentro de la clase “B”.

La ecuación de la recta que resulta de la combinación entre entradas y pesos sinápticos actúa como discriminante de las clases asociadas a las entradas de la red (Figura N° 17) y será de la forma:

$$\omega_1 x_1 + \omega_2 x_2 + \Theta = 0 \quad (1.8)$$

El umbral ( $\Theta$ ) representado en la expresión 3.11, se conoce también con el nombre de bias ( $b$ ) y puede ser escrito como se muestra en la ecuación.

$$\omega_1 x_1 + \omega_2 x_2 + b = 0 \quad (1.9)$$

Las dos entradas de la red neuronal pueden ser representadas en un espacio bidimensional, y la ecuación de la recta señalada anteriormente actúa en el mismo espacio separando los patrones ingresados en dos categorías o clases. El aprendizaje del perceptrón consiste entonces en encontrar los parámetros de la ecuación de la recta que sirve como discriminante en el problema de clasificación que se trata de resolver (Isasi Viñueta Pedro, 2004).




Figura N° 17: Estructura general de una neurona del tipo perceptrón

En caso de que dentro de los datos a clasificar no existan únicamente dos clases, la discriminación de las mismas no se podrá realizar con rectas y será necesario definir hiperplanos.




Figura N° 18: Discriminación de clases por un Perceptrón

La separación en clases se realiza considerando las siguientes condiciones:

El Punto P ( $a_1, b_1$ ) pertenece a la clase A si  $\omega_1 a_1 + \omega_2 a_2 + b < 0$

Y pertenece a la clase B si  $\omega_1 a_1 + \omega_2 a_2 + b > 0$

Lo anteriormente dicho aplica para un problema de clasificación bidimensional, sin embargo el empleo del perceptrón como clasificador no se limita a este nivel de análisis y en forma genérica las ecuaciones anteriores se mostrarían de la siguiente forma:

El punto  $P(a_1, a_2, a_3, \dots, a_n)$

Pertenece a la clase A si  $\omega_1 a_1 + \omega_2 a_2 + \omega_3 a_3 + \dots + \omega_n a_n + b < 0$

Y pertenece a la clase B si  $\omega_1 a_1 + \omega_2 a_2 + \omega_3 a_3 + \dots + \omega_n a_n + b > 0$

Si se cumple la primera condición la función de transferencia de la red neuronal generará la salida -1 lo cual equivale a clasificar la entrada dentro de la categoría "A", y en caso contrario si se cumple la segunda condición la red proporciona una salida de 1 lo que clasifica al patrón de entrada dentro de la categoría "B".

El entrenamiento de una red neuronal del tipo perceptrón consiste en introducir uno a uno los patrones de entrenamiento con la finalidad de obtener errores al comparar las salidas que genera la red con las salidas deseadas (targets), estos errores son útiles para ajustar los pesos mediante un algoritmo de aprendizaje, los pesos ajustados aproximarán en forma cada vez mejor a las salidas de la red con respecto a los targets.

Si la salida de la red para un ejemplo de entrenamiento es menor que la salida deseada, entonces se debe efectuar un incremento en los pesos con la finalidad de que la salida pueda ser mayor y supere al umbral, si por el contrario, la salida es mayor que la esperada, los pesos tendrán que sufrir un decremento para que el valor generado por la red no supere al del umbral.

El procedimiento a seguir es el siguiente, si al introducir uno de los patrones de entrenamiento la salida que produce la red es igual a la salida deseada, entonces se introduce el siguiente patrón sin hacer modificaciones en los pesos, si por el



contrario la salida de la red no es igual a la esperada, entonces se realiza un ajuste de los pesos de acuerdo al algoritmo de aprendizaje, el procedimiento se repite hasta que todos los patrones generan salidas que coinciden con sus respectivos targets.

### 2.4.9 Funciones de transferencia

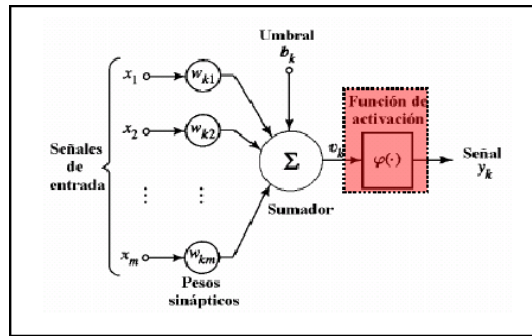


Figura N° 19: Función de transferencia

En las redes neuronales existe una función sea esta lineal o no lineal, que permite cambiar de nivel de activación a partir de las señales que recibe, ésta función es conocida como función de activación o transferencia.

$$U_k = \sum_{j=1} W_{kj} X_j + b_k$$

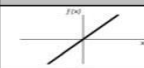

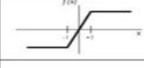


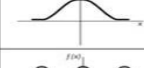

	FUNCIÓN	RANGO	GRAFICA
IDENTIDAD	$y = x$	$[-\infty, +\infty]$	
ESCALÓN	$y = \text{signo}(x)$ $y = H(x)$	$[-1, +1]$ $[0, +1]$	
LINEAL A TRAMOS		$[-1, +1]$	
SIGMOIDEA LOGÍSTICA	$f(x) = \frac{1}{1 + e^{-x}}$	$[0, +1]$	
SIGMOIDEA TANGENTE HIPERBÓLICA	$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}}$	$[-1, +1]$	
GAUSSIANA	$y = A \cdot e^{-Bx^2}$	$[0, +1]$	
SINUSOIDAL	$y = A \cdot \text{sen}(\omega x + \phi)$	$[-1, +1]$	

Figura N° 20: Funciones de activación

Fuente: Bonifacio Martín 2001

Se usa como función de activación una relación lineal (identidad) para neuronas de entrada a la red o sensores. Esto se debe a que un sensor tiene que indicar lo que está

percibiendo. Si la función de activación de una neurona es lineal entonces se dice que es una neurona lineal, en caso contrario se dice que es una neurona no lineal.

Las tres primeras funciones presentan una desventaja porque no son derivables en algunos puntos por lo que no pueden aplicarse algunos algoritmos de aprendizaje, es por ello que la tendencia es utilizar funciones que sean diferenciables en todos sus puntos como es el caso de la función sigmoidea la misma que presenta dos formas, una logística y otra tangente hiperbólica.

De acuerdo a la experiencia de varios investigadores en el estudio de las RNA se recomienda la utilización de ésta función.

#### **2.4.10 Arquitectura de una red neuronal artificial**

La topología o arquitectura de una red consiste en la organización y disposición de las neuronas en la red, formando capas de neuronas, en este sentido existen varios parámetros que se deben de tomar en consideración cuando se define una RNA como son: el número de capas, el número de neuronas por capa, su grado de conectividad y el tipo de conexión existente entre las neuronas.

En las RNA las conexiones sinápticas son direccionales, es decir, la información únicamente puede propagarse en un único sentido de izquierda a derecha, desde la neurona presináptica a la postsináptica.

En una red neuronal artificial las neuronas se encuentran agrupadas, conectadas entre sí en unidades estructurales denominadas capas. En relación a la estructura en capas se pueden definir redes monocapa y redes multicapa. Las redes monocapa son aquellas compuestas por una única capa de neuronas, en donde las neuronas de la capa de entrada constituyen también las de salida. Las redes multicapa son aquellas cuyas neuronas se organizan en varias capas y según la función que desempeñan suelen recibir

un nombre específico. Se pueden distinguir tres tipos de capas (Isasi Viñueta Pedro, 2004)(Martin, 2001) (Haykin, 2001).

- De entrada: También llamada sensorial, está formada por neuronas que reciben datos o señales provenientes del entorno. Aquí se encuentran las variables que definen el problema.
- Ocultas: Son aquellas que no poseen una conexión directa con el entorno, aquí es donde se genera la representación de la información y se realizan todas las conexiones neuronales posibles (dependiendo del problema a resolver) entre todas las capas.
- De salida: Es aquella en donde se transfiere la información de la red hacia el exterior, es decir, proporciona la respuesta.

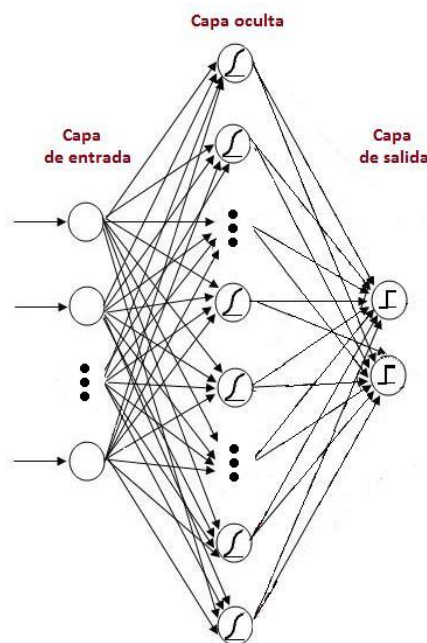


Figura N° 21: Esquema de topología feedforward

También de acuerdo a la forma en la que se dirigen los datos en la red neuronal, se puede clasificar en redes unidireccionales (feedforward) y redes recurrentes (feedback).

En las redes unidireccionales la información circula en un solo sentido, desde las neuronas de entrada hacia las de salida (izquierda a derecha), estas redes son una generalización de los perceptrones multicapa (MLP), que constituyen la categoría de topologías más utilizada en computación neuronal; mientras que en las redes recurrentes o realimentadas la información puede circular entre las capas en cualquier sentido incluyendo el de salida-entrada.

La red que se usara en el presente proyecto será (red feedforward).

#### **2.4.11 Red Neuronal Multicapa**

La topología de una red neuronal multicapa o MLP (Multilayer Perceptrons) está constituida como su nombre lo indica por una o varias capas en este caso ocultas, además de las capas de entrada y salida.

Las capas ocultas tienen la finalidad de realizar un procesamiento no lineal por medio de la función de activación, de los patrones de aprendizaje, capacitando así a la red a aprender y solucionar problemas complejos. En los MLP las neuronas de una capa se conectan con las neuronas de la siguiente capa con una conectividad total, en donde cada neurona de la red es afectada por la actividad de todas las otras neuronas en la red; se las denomina redes alimentadas hacia delante o redes feedforward por el sentido en que va la información (izquierda a derecha).




Figura N° 22: Arquitectura de una Red Neuronal Multicapa

El entrenamiento de un Perceptrón Multicapa utiliza un aprendizaje supervisado con un algoritmo de aprendizaje de retropropagación del error o backpropagation, el cual está basado en la regla de aprendizaje por corrección del error. La retropropagación de los errores medidos en la salida de la red hacia las neuronas ocultas se lo hace a través de una generalización de la regla delta o LMS (Least Mean Square).

### III. MATERIALES Y MÉTODOS

#### 3.1 EQUIPOS Y MATERIALES

##### 3.1.1 Equipos

- **Receptor GNSS Topcon GR3**

Tabla N°2

*Especificaciones Técnicas GNSS Base y Rover*

ESPECIFICACIONES	
Número de canales	72
Señales rastreadas	GPS L1, L2, & L5 portadora, CA, L1 P, L2 P, L2C, GLONASS L1, L2, & L5 portadora, L1CA, L2CA, L1, P, L2 P GALILEO E2-L1- E1, E5
WAAS/EGNOS/MSAS	SI
TIPO DE ANTENA	INTEGRADA
PRESICION	
PRESICION	
RTK	H: 10MM+1PPM, V: 15MM+1PPM
Estático	H: 3MM+0.5PPM V: 5MM+0.5M
COMUNICACIONES	
Bluetooth	: SI
SD	: SI
Radio	: INTEGRADO UHF TX/RX
Celular	: SIM/GPRS/CDMA
DATOS Y MEMORIA	: Memoria SD
Protección al polvo/agua	: IP66
Grado de choque	: 2 MTR SOBRE HORMIGON
Temperatura de operación	: - 40°C – 60°C
Software	: TOPCON TOOLS

Fuente: Manual de usuario GNSS Topcon GR3

- **Nivel Leica NA-720**

Tabla N°3  
*Especificaciones Técnicas Nivel Leica N-720*

ESPECIFICACIONES TECNICAS	
Imagen	Directa
Aumento	20X
Diámetro del objetivo	30 mm
Enfoque min. 0.5 m	0.5 m
Precisión	+/- 1.5 mm
Nivel esférico 10'	
Peso	1.6 kg
Círculo	horizontal
Tornillo sin fin por el movimiento horizontal	

Fuente: Manual de usuario Leica N720

**3.1.2 Materiales**

Materiales necesarios para la fijación de puntos

- Arena
- Cemento
- Agua
- Pintura
- Pernos de 3"

**3.1.3 Herramientas informáticas**

- Topcon Tools
- Trimble Busines Center
- Autodesk Civil 3D
- Golden Surfer 13.0
- Matlab
- Microsoft Excel
- Microsoft Word
- Microsurvey Starnet



## 3.2 DESARROLLO METODOLÓGICO

### 3.2.1 Delimitación del área de estudio



*Figura N° 23: Perímetro de Área de estudio*  
Fuente: Elaboración propia.

El área donde se desarrolla el estudio, corresponde a la zona norte de la ciudad de Puno.

Para la elaboración del presente proyecto, se realizó la densificación de puntos en lugares estratégicos los cuales se ubicarán en la zona Norte de la Ciudad de PUNO limitadas por el Sur con la Av. Floral, Intersección con Av. La Torre, por el Oeste limita la Av. La Torre, las cuales involucran las siguientes Sub Zonas:

- Campus de la Ciudad Universitaria
- Barrio Bellavista
- Urb. Alto Bellavista
- Urb. Machallata
- Urb. Virgen de Copacabana



- Urb. Llavini Quintanilla Chacon
- Urb. Aprovi
- Urb. Union Llavini I Etapa
- Urb. Alto Alianza

### 3.3 DATOS NECESARIOS

La información que se requiere para el entrenamiento de la red neuronal consiste en un conjunto de datos puntuales distribuidos regularmente dentro del área de estudio. Dichos puntos deben estar enlazados a un punto de la red de nivelación nacional, en los cuales se ha realizado posicionamiento satelital de precisión en modo estático, es por lo tanto posible calcular en estos sitios la diferencia existente entre las alturas niveladas y las alturas elipsoidales correspondientes (ondulaciones geoidales), siendo esta la variable que la red deberá aprender a generalizar.

En el área de estudio se han realizado campañas de nivelación geométrica con el objetivo de optimizar la calidad de los resultados.

### 3.4 DATOS EXISTENTES

#### 3.4.1 PUNTOS GNSS

Los datos de puntos de GNSS que se han empleado para este proyecto de investigación se densificaron para cubrir el área de estudio, estos puntos tuvieron como punto inicial (BASE) el Punto de Control Geodésico de orden "B" **PNO1** ubicado en el MIRADOR MUNICIPAL KUNTUR WASI, en el extremo oeste. Establecidos por el Instituto Geográfico Nacional (IGN).

Tabla N°4  
*Coordenadas geográficas y altura elipsoidal Base PN01*

Código	Ubicación	Latitud	Longitud	(h)
PN01	MIRADOR MUNICIPAL KUNTUR WASI	15°50'49.0392"	70°01'48.3719"	4037.744

Fuente: Ficha monográfica del Instituto Geográfico Nacional – Dirección de Geodésia emitido en agosto 2008

### 3.4.2 ALTURA NIVELADA

Tabla N°5  
*Altura nivelada, Red de Nivelación Nacional*

Código	Ubicación	Altura Nivelada (H)
PFCV AUX-01 PUN	Parque Manuel Pino	3828.4108

Fuente: Ficha monográfica del Instituto geográfico Nacional, Tramo de nivelación (Puno –Desaguadero-Matarani) emitido en enero 2017

## 3.5 OBTENCION DE DATOS

### 3.5.1 POSICIONAMIENTO DE PRESICION

Se empleó 02 quipos GNSS Topcon GR-3, el primero se instaló en el punto base PNO1, y el punto “Base B”, que se encuentra dentro del perímetro del proyecto, esto con la finalidad de trasladar el punto Base para la posterior densificación de puntos.

Ubicado el nuevo punto base “BASE B”, se comienza la recolección de datos. Los puntos fueron obtenidos mediante un posicionamiento GNSS estático durante periodos de 15min y empleando un equipo de doble frecuencia.

Los datos crudos se descargaron y posteriormente se transformaron en datos Rinex, para luego realizar el post proceso con el software especializado Trimble Business Center 3.5 (TBC).

Para realizar el postproceso del registro de datos de campo, se empleó como base el punto **PNO1**.



Figura N° 24: Visualización de Líneas Base

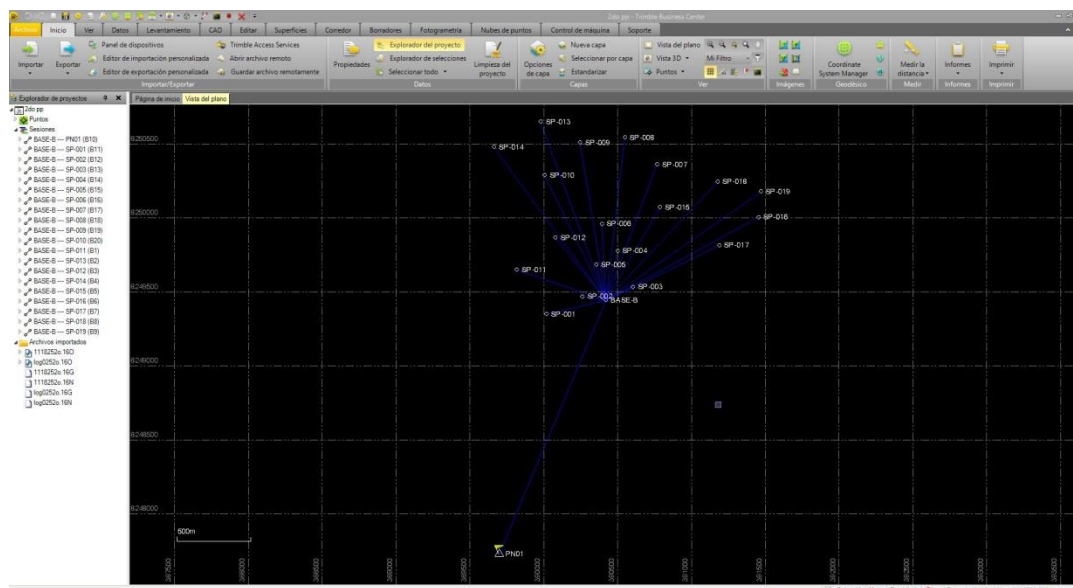


Figura N° 25: Entorno Trimble Business Center 3.5.0

Tabla N°6  
*Reporte de Post Procesamiento de Línea Base*

De	A	Tipo de solución	Prec. H. (Metro)	Prec. V. (Metro)	Aci. geod.	Dist. elip (Metro)	ΔAltura (Metro)
PN01	BASE-B	Fija	0.004	0.006	23°07'21"	1866.091	-139.249
BASE-B	SP-001	Fija	0.005	0.009	257°05'45"	416.173	-26.358
BASE-B	SP-003	Fija	0.004	0.005	64°17'53"	201.664	-9.778
BASE-B	SP-004	Fija	0.003	0.007	13°20'01"	341.595	6.128
BASE-B	SP-005	Fija	0.002	0.005	344°29'53"	247.612	50.528
BASE-B	SP-006	Fija	0.002	0.005	357°03'30"	515.913	71.137
BASE-B	SP-007	Fija	0.009	0.010	20°52'51"	980.179	-27.376
BASE-B	SP-008	Fija	0.004	0.006	6°49'49"	1107.533	-16.897
BASE-B	SP-009	Fija	0.006	0.013	350°53'50"	1077.522	3.898
BASE-B	SP-010	Fija	0.003	0.006	333°58'50"	939.858	41.488
BASE-B	SP-011	Fija	0.005	0.010	289°02'03"	640.192	-10.942
BASE-B	SP-013	Fija	0.004	0.008	340°05'37"	1282.708	73.453
BASE-B	SP-012	Fija	0.005	0.006	321°08'03"	543.907	103.653
BASE-B	SP-014	Fija	0.003	0.009	323°57'22"	1282.775	97.967
BASE-B	SP-015	Fija	0.002	0.007	30°30'04"	724.545	47.049
BASE-B	SP-016	Fija	0.006	0.008	61°45'39"	1174.230	-38.077
BASE-B	SP-017	Fija	0.004	0.007	64°30'56"	851.770	-37.948
BASE-B	SP-018	Fija	0.004	0.008	43°34'58"	1099.960	-34.335
BASE-B	SP-019	Fija	0.004	0.010	55°18'08"	1279.119	-17.265
BASE-B	SP-002	Fija	0.004	0.004	279°01'13"	162.913	4.069

Fuente: Trimble Busines Center

Tabla N°7  
*Reporte de Coordenadas Geográficas y Alturas Elipsoidales*

ID	Latitud (Global)	Longitud (Global)	Altura (Global) (Metro)	Factor de escala de proyección	Factor de escala de altura	Factor de escala combinada
BAS E-B	S15°49'53.2062 5"	O70°01'23.74516"	3898.284	0.9997484 898	0.9993893 307	0.9991379 741
PN01	S15°50'49.0392 0"	O70°01'48.37190"	4037.744	0.9997504 588	0.9993674 982	0.9991181 149
SP-001	S15°49'56.2297 3"	O70°01'37.37793"	3871.926	0.9997495 898	0.9993934 572	0.9991431 988
SP-002	S15°49'52.3752 6"	O70°01'29.15231"	3902.352	0.9997489 264	0.9993886 937	0.9991377 736
SP-003	S15°49'50.3609 2"	O70°01'17.63857"	3888.506	0.9997479 990	0.9993908 615	0.9991390 140
SP-004	S15°49'42.3927 0"	O70°01'21.09778"	3904.412	0.9997482 809	0.9993883 713	0.9991368 061

SP-005	S15°49'45.4437 5"	O70°01'25.96915"	3948.812	0.9997486 724	0.9993814 202	0.9991302 481
SP-006	S15°49'36.4441 7"	O70°01'24.63489"	3969.421	0.9997485 684	0.9993781 939	0.9991269 186
SP-007	S15°49'23.4122 7"	O70°01'12.00508"	3870.907	0.9997475 569	0.9993936 165	0.9991413 264
SP-008	S15°49'17.4305 9"	O70°01'19.31897"	3881.387	0.9997481 478	0.9993919 758	0.9991402 767
SP-009	S15°49'18.5926 8"	O70°01'29.47369"	3902.181	0.9997489 663	0.9993887 203	0.9991378 401
SP-010	S15°49'25.7287 9"	O70°01'37.60016"	3939.771	0.9997496 204	0.9993828 355	0.9991326 104
SP-011	S15°49'46.4135 1"	O70°01'44.08296"	3887.342	0.9997501 370	0.9993910 437	0.9991413 328
SP-012	S15°49'39.4286 0"	O70°01'35.21472"	4001.937	0.9997494 217	0.9993731 035	0.9991226 823
SP-013	S15°49'13.9691 3"	O70°01'38.42147"	3971.737	0.9997496 918	0.9993778 311	0.9991276 786
SP-014	S15°49'19.4623 4"	O70°01'49.10951"	3996.251	0.9997505 560	0.9993739 935	0.9991247 057
SP-015	S15°49'32.8964 1"	O70°01'11.38696"	3945.332	0.9997475 033	0.9993819 649	0.9991296 243
SP-016	S15°49'35.1305 1"	O70°00'48.98147"	3860.206	0.9997457 073	0.9993952 918	0.9991411 529
SP-017	S15°49'41.2829 5"	O70°00'57.90606"	3860.336	0.9997464 185	0.9993952 716	0.9991418 435
SP-018	S15°49'27.2839 9"	O70°00'58.26207"	3863.949	0.9997464 527	0.9993947 059	0.9991413 121
SP-019	S15°49'29.5170 1"	O70°00'48.40460"	3881.019	0.9997456 635	0.9993920 335	0.9991378 516

Fuente: Reporte de procesamiento de línea base (TBC)

Tabla N°8

*Reporte de Coordenadas UTM y Alturas Geoidales EGM96*

ID	Este (Metro)	Norte (Metro)	Elevación (Metro)	Factor de escala de proyección	Factor de escala de altura	Factor de escala combinada
BASE-B	390423.231	8249442.004	3852.861	0.9997484898	0.9993893307	0.9991379741
PN01	389699.036	8247722.674	3992.102	0.9997504588	0.9993674982	0.9991181149
SP-001	390018.128	8249347.112	3826.501	0.9997495898	0.9993934572	0.9991431988
SP-002	390262.251	8249466.756	3856.929	0.9997489264	0.9993886937	0.9991377736
SP-003	390604.469	8249530.325	3843.084	0.9997479990	0.9993908615	0.9991390140
SP-004	390500.370	8249774.687	3858.990	0.9997482809	0.9993883713	0.9991368061
SP-005	390355.907	8249680.222	3903.389	0.9997486724	0.9993814202	0.9991302481
SP-006	390394.252	8249956.972	3923.999	0.9997485684	0.9993781939	0.9991269186
SP-007	390768.038	8250359.269	3825.489	0.9997475569	0.9993936165	0.9991413264
SP-008	390549.556	8250542.028	3835.968	0.9997481478	0.9993919758	0.9991402767
SP-009	390247.625	8250504.846	3856.760	0.9997489663	0.9993887203	0.9991378401
SP-010	390006.933	8250284.373	3894.348	0.9997496204	0.9993828355	0.9991326104



SP-011	389817.184	8249647.788	3841.916	0.9997501370	0.9993910437	0.9991413328
SP-012	390079.957	8249863.725	3956.513	0.9997494217	0.9993731035	0.9991226823
SP-013	389980.732	8250645.628	3926.315	0.9997496918	0.9993778311	0.9991276786
SP-014	389663.587	8250475.265	3950.826	0.9997505560	0.9993739935	0.9991247057
SP-015	390787.841	8250067.912	3899.913	0.9997475033	0.9993819649	0.9991296243
SP-016	391454.725	8250002.484	3814.790	0.9997457073	0.9993952918	0.9991411529
SP-017	391190.138	8249812.138	3814.918	0.9997464185	0.9993952716	0.9991418435
SP-018	391177.466	8250242.273	3818.532	0.9997464527	0.9993947059	0.9991413121
SP-019	391471.054	8250175.069	3835.603	0.9997456635	0.9993920335	0.9991378516

Fuente: Reporte de procesamiento de línea base (TBC)

### 3.5.2 NIVELACION GEOMETRICA

La nivelación geométrica consiste en medir diferencias de altitud entre dos puntos separados unos pocos metros por medio de la diferencia de lecturas directas hechas sobre dos reglas graduadas (miras) situadas en ellos, con un instrumento perfectamente horizontal situado en el punto medio.

Iniciamos la jornada de nivelación estableciendo como punto de partida el BM con altura nivelada “PFCV AUX01-PUN” punto que está ubicado en el centro del parque Manuel Pino

El tipo de nivelación que se realizó es “Nivelación Geométrica Compuesta Doble” con clasificación de Nivelación Ordinaria con tolerancia de  $0.007 * \sqrt{K}$ .

Luego de haber colectado los datos de nivelación por circuitos cerrados, se procede a determinar los desniveles de punto a punto, para su posterior compensación utilizando el software Microsurvey Starnet

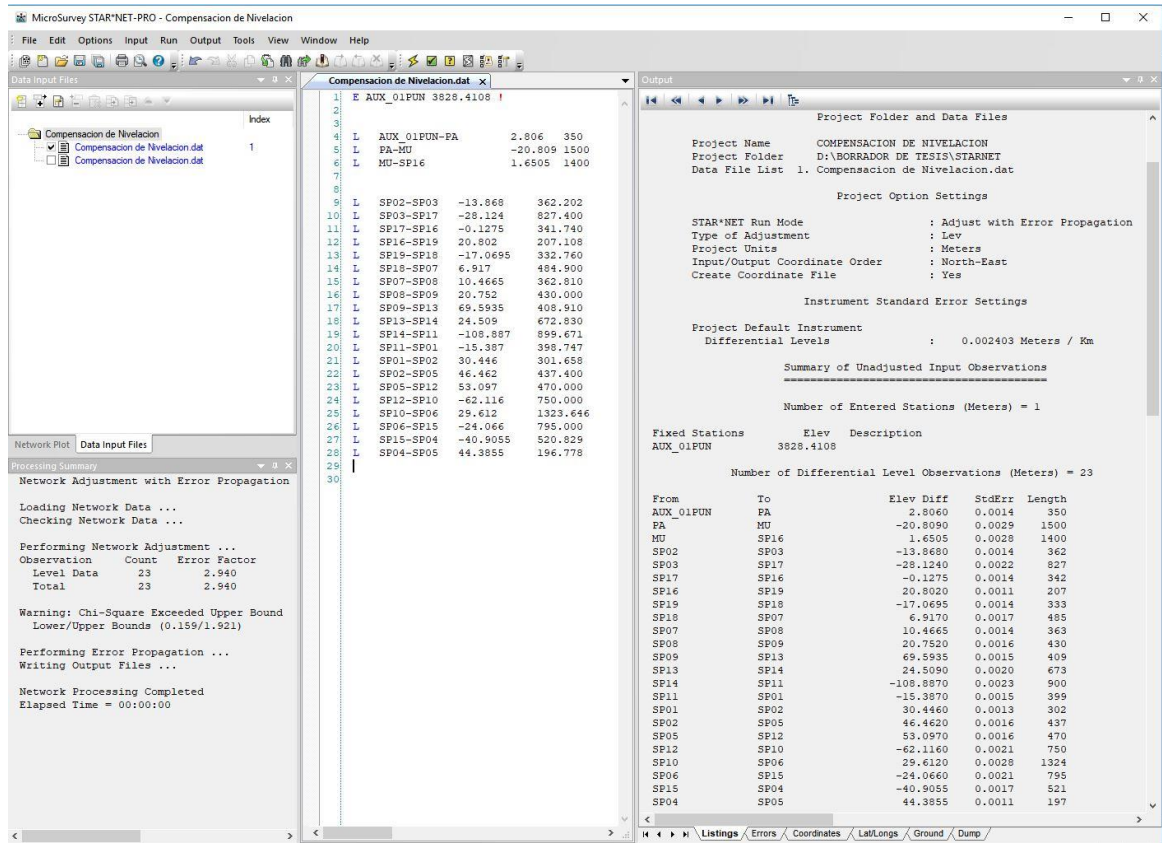


Figura N° 26: Entorno de Microsurvey Starnet para la compensación de Nivelación Versión de prueba de 10 días

Tabla N°9  
Circuito de nivelación I

INICIO	FIN	DE	StdErr	LONG
AUX_01PUN	PA	2.806	0.0014	350
PA	MU	-20.809	0.0029	1500
MU	SP16	1.6505	0.0028	1400

Desniveles compensados – Microsurvey Starnet

Tabla N°10  
Circuito de nivelación II

INICIO	FIN	DE	StdErr	LONG
SP02	SP03	-13.868	0.0014	362
SP03	SP17	-28.124	0.0022	827
SP17	SP16	-0.1275	0.0014	342
SP16	SP19	20.802	0.0011	207
SP19	SP18	-17.0695	0.0014	333
SP18	SP07	6.917	0.0017	485
SP07	SP08	10.4665	0.0014	363
SP08	SP09	20.752	0.0016	430
SP09	SP13	69.5935	0.0015	409

SP13	SP14	24.509	0.002	673
SP14	SP11	-108.887	0.0023	900
SP11	SP01	-15.387	0.0015	399

Desniveles compensados – Microsurvey Starnet

Tabla N°11  
*Circuito de nivelación III*

INICIO	FIN	DE	StdErr	LONG
SP01	SP02	30.446	0.0013	302
SP02	SP05	46.462	0.0016	437
SP05	SP12	53.097	0.0016	470
SP12	SP10	-62.116	0.0021	750
SP10	SP06	29.612	0.0028	1324
SP06	SP15	-24.066	0.0021	795
SP15	SP04	-40.9055	0.0017	521
SP04	SP05	44.3855	0.0011	197

Desniveles compensados – Microsurvey Starnet

Tabla N°12  
*Observaciones y residuos ajustados (metros)*

From	To	Elev Diff	Residual	StdErr	StdRes	File:Line
AUX_01PUN	PA	2.806	0.0000	0.0014	0	01:04
PA	MU	-20.809	0.0000	0.0029	0	01:05
MU	SP16	1.6505	0.0000	0.0028	0	01:06
SP02	SP03	-13.8694	-0.0014	0.0014	1	01:09
SP03	SP17	-28.1272	-0.0032	0.0022	1.4	01:10
SP17	SP16	-0.1288	-0.0013	0.0014	0.9	01:11
SP16	SP19	20.8012	-0.0008	0.0011	0.7	01:12
SP19	SP18	-17.0708	-0.0013	0.0014	0.9	01:13
SP18	SP07	6.9152	-0.0018	0.0017	1.1	01:14
SP07	SP08	10.4651	-0.0014	0.0014	1	01:15
SP08	SP09	20.7504	-0.0016	0.0016	1	01:16
SP09	SP13	69.5919	-0.0016	0.0015	1	01:17
SP13	SP14	24.5064	-0.0026	0.002	1.3	01:18
SP14	SP11	-108.8904	-0.0034	0.0023	1.5	01:19
SP11	SP01	-15.3885	-0.0015	0.0015	1	01:20
SP01	SP02	30.4448	-0.0012	0.0013	0.9	01:21
SP02	SP05	46.462	0	0.0016	0	01:22
SP05	SP12	53.0962	-0.0008	0.0016	0.5	01:23
SP12	SP10	-62.1173	-0.0013	0.0021	0.6	01:24
SP10	SP06	29.6097	-0.0023	0.0028	0.8	01:25
SP06	SP15	-24.0674	-0.0014	0.0021	0.6	01:26



SP15	SP04	-40.9064	-0.0009	0.0017	0.5	01:27
SP04	SP05	44.3852	-0.0003	0.0011	0.3	01:28

Fuente Microsurvey Starnet

Tabla N°13  
*Alturas Ajustadas y propagación de errores (metros)*

Station	Elev	StdDev	95% Description
AUX_01PUN	3828.4108	0	0.000001
PA	3831.2168	0.004179	0.008191
MU	3810.4078	0.009608	0.018831
SP16	3812.0583	0.012735	0.024959
SP02	3854.1836	0.014805	0.029017
SP03	3840.3143	0.014464	0.028348
SP17	3812.1871	0.013351	0.026168
SP19	3832.8595	0.013121	0.025716
SP18	3815.7887	0.013664	0.02678
SP07	3822.7039	0.014304	0.028036
SP08	3833.169	0.014679	0.028771
SP09	3853.9194	0.015018	0.029434
SP13	3923.5113	0.01524	0.02987
SP14	3948.0177	0.015404	0.030192
SP11	3839.1273	0.015242	0.029874
SP01	3823.7388	0.015028	0.029454
SP05	3900.6456	0.015524	0.030427
SP12	3953.7418	0.016178	0.031709
SP10	3891.6245	0.01684	0.033005
SP06	3921.2343	0.01698	0.033281
SP15	3897.1669	0.016446	0.032234
SP04	3856.2605	0.015822	0.031011

Desniveles compensados – Microsurvey Starnet

Tabla N°14  
*Alturas Niveladas (H)*

<b>CODIGO</b>	<b>Altura Nivelada (H)</b>
PFCHV-AUX-01 PUN	3828.411
SP-001	3823.739
SP-002	3854.184
SP-003	3840.314
SP-004	3856.261
SP-005	3900.646
SP-006	3921.234
SP-007	3822.704

SP-008	3833.169
SP-009	3853.919
SP-010	3891.625
SP-011	3839.127
SP-012	3953.742
SP-013	3923.511
SP-014	3948.018
SP-015	3897.167
SP-017	3812.187
SP-016	3812.058
SP-018	3815.789
SP-019	3832.860

Datos necesarios para el entrenamiento de la red neuronal artificial

### 3.6 ENTRENAMIENTO DE RED NEURONAL

#### 3.6.1 Definición de Sub Conjunto de Entrenamiento

Los 20 puntos considerados para el entrenamiento de la red neuronal artificial (RNA), 01 corresponde al obtenido por el IGN (punto con la altura nivelada - PFCV-AUX-01 PUN ) y 19 a los obtenidos en campañas GNSS realizadas para complementar la información dentro del área de estudio. Para realizar el entrenamiento de la RNA, es necesario definir tres subconjuntos del total de datos disponibles, un grupo de datos para el entrenamiento propiamente dicho, otro conjunto de validación y un tercer conjunto de test. Los datos del conjunto de entrenamiento son empleados para realizar el ajuste de los pesos sinápticos, en base a la comparación de sus salidas deseadas y las salidas que genera la red, los datos del conjunto de validación proporcionan una idea de hasta qué punto la red es capaz de generalizar, esto significa que los datos del conjunto de entrenamiento ingresan iterativamente a la red durante el entrenamiento mientras la modificación en los pesos sinápticos repercute en una reducción de los errores que genera la misma para los datos del conjunto de validación; es por este motivo que se considera que los datos de validación participan en el aprendizaje.

Por lo tanto se hace necesario contar con un conjunto de datos que no se encuentren involucrados de ninguna forma en el proceso de aprendizaje de la RNA, de tal forma que los errores que se generen para estos datos, brinden una estimado sin sesgos de la capacidad de generalización de la red, a este subconjunto se lo conoce como datos de test.

Se emplearon 15 datos para el conjunto de entrenamiento, 15 para validación que son los mismos del entrenamiento y 4 para test (Figura N° 28), los datos test fueron escogidos basándose en los criterios de representatividad y significancia al igual que para los datos de entrenamiento.

La totalidad de datos disponibles para el aprendizaje de la red, será el principal condicionante para definir el número de elementos con que cuente cada subconjunto, el número de datos de entrenamiento determina la cantidad de información disponible para que la red pueda obtener el aprendizaje, por su parte los datos de los subconjuntos de validación y test aportan información importante sobre la capacidad de generalización que alcanza la red durante el entrenamiento, de tal forma que si se destina un número elevado en proporción al total de datos disponibles para los subconjuntos de validación y test, se limitará la cantidad de información con que se cuenta para realizar el entrenamiento de la red.

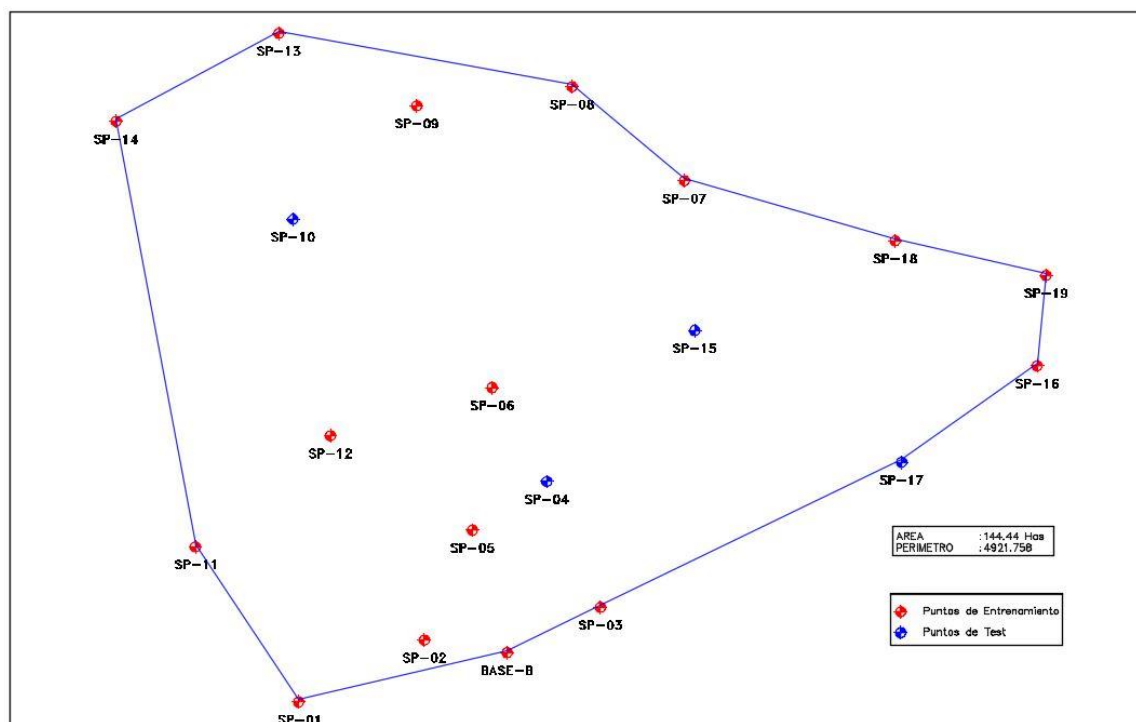


Figura N° 27: Sub Conjuntos de entrenamiento  
Fuente: Elaboración propia

Definidos los subconjuntos de entrenamiento según (Figura N° 28), procedemos a consolidar la lista de puntos con sus respectivos valores, que son Este, Norte, Altura Elipsoidal (h), Altura nivelada (H).

Tabla N°15  
Lista de Puntos para Entrenamiento

CODIGO	Norte	Este	h	H	N
SP-001	8249347.112	390018.128	3871.926	3823.739	48.187
SP-002	8249466.756	390262.251	3902.352	3854.184	48.168
SP-003	8249530.325	390604.469	3888.506	3840.314	48.192
SP-004	8249774.687	390500.37	3904.412	3856.261	48.151
SP-005	8249680.222	390355.907	3948.812	3900.646	48.166
SP-006	8249956.972	390394.252	3969.421	3921.234	48.187
SP-007	8250359.269	390768.038	3870.907	3822.704	48.203
SP-008	8250542.028	390549.556	3881.387	3833.169	48.218
SP-009	8250504.846	390247.625	3902.181	3853.919	48.262
SP-010	8250284.373	390006.933	3939.771	3891.625	48.147
SP-011	8249647.788	389817.184	3887.342	3839.127	48.215

SP-012	8249863.725	390079.957	4001.937	3953.742	48.195
SP-013	8250645.628	389980.732	3971.737	3923.511	48.226
SP-014	8250475.265	389663.587	3996.251	3948.018	48.233
SP-015	8250067.912	390787.841	3945.332	3897.167	48.165
SP-017	8249812.138	391190.138	3860.336	3812.187	48.149
SP-016	8250002.484	391454.725	3860.206	3812.058	48.148
SP-018	8250242.273	391177.466	3863.949	3815.789	48.160
SP-019	8250175.069	391471.054	3881.019	3832.860	48.159

Fuente: Elaboración propia

Tabla N°16

*Subconjunto de Entrenamiento*

<b>CODIGO</b>	<b>Norte</b>	<b>Este</b>	<b>h</b>	<b>H</b>	<b>N</b>
SP-001	8249347.112	390018.128	3871.926	3823.739	48.187
SP-002	8249466.756	390262.251	3902.352	3854.184	48.168
SP-003	8249530.325	390604.469	3888.506	3840.314	48.192
SP-005	8249680.222	390355.907	3948.812	3900.646	48.166
SP-006	8249956.972	390394.252	3969.421	3921.234	48.187
SP-007	8250359.269	390768.038	3870.907	3822.704	48.203
SP-008	8250542.028	390549.556	3881.387	3833.169	48.218
SP-009	8250504.846	390247.625	3902.181	3853.919	48.262
SP-011	8249647.788	389817.184	3887.342	3839.127	48.215
SP-012	8249863.725	390079.957	4001.937	3953.742	48.195
SP-013	8250645.628	389980.732	3971.737	3923.511	48.226
SP-014	8250475.265	389663.587	3996.251	3948.018	48.233
SP-016	8250002.484	391454.725	3860.206	3812.058	48.148
SP-018	8250242.273	391177.466	3863.949	3815.789	48.160
SP-019	8250175.069	391471.054	3881.019	3832.860	48.159

Fuente: Elaboración propia

Tabla N°17

*Subconjunto Test*

<b>CODIGO</b>	<b>Norte</b>	<b>Este</b>	<b>h</b>	<b>H</b>	<b>N</b>
SP-004	8249774.687	390500.37	3904.412	3856.261	48.151
SP-010	8250284.373	390006.933	3939.771	3891.625	48.147
SP-015	8250067.912	390787.841	3945.332	3897.167	48.165
SP-017	8249812.138	391190.138	3860.336	3812.187	48.149

Fuente: Elaboración propia

**3.6.2 Estructura de la red neuronal artificial**

En el caso de nuestra red neuronal que tiene como datos de entrada este, norte, altura elipsoidal, se estableció luego de un procedimiento de prueba error una arquitectura de tres capas, (01) capa de entrada con 03 neuronas, (01) capa oculta con 17 neuronas, (01) capa de salida con 01 neurona.




Figura N° 28: Estructura de la red neuronal artificial  
Fuente: Elaboración propia.

Tabla N°18  
Datos para la capa de entrada

CODIGO	Norte	Este	h
SP-001	8249347.112	390018.128	3871.926
SP-002	8249466.756	390262.251	3902.352
SP-003	8249530.325	390604.469	3888.506
SP-005	8249680.222	390355.907	3948.812
SP-006	8249956.972	390394.252	3969.421
SP-007	8250359.269	390768.038	3870.907
SP-008	8250542.028	390549.556	3881.387
SP-009	8250504.846	390247.625	3902.181
SP-011	8249647.788	389817.184	3887.342
SP-012	8249863.725	390079.957	4001.937
SP-013	8250645.628	389980.732	3971.737
SP-014	8250475.265	389663.587	3996.251

SP-016	8250002.484	391454.725	3860.206
SP-018	8250242.273	391177.466	3863.949
SP-019	8250175.069	391471.054	3881.019

Las columnas norte, este, h, corresponden a las neuronas de la capa de entrada

Tabla N°19  
 Datos para la capa de salida

CODIGO	N
SP-004	48.151
SP-010	48.147
SP-015	48.165
SP-017	48.149

La columna N corresponde a la neurona de la capa de salida

Con la utilización del software Matlab R2015, procedemos a realizar el pre procesamiento de los datos, preparamos un escript para poder ingresar los datos de entrada y salida en formato .txt y luego cargarlos en el software, generamos la transpuesta de cada matriz ya que el programa matlab reconoce las filas como variables.

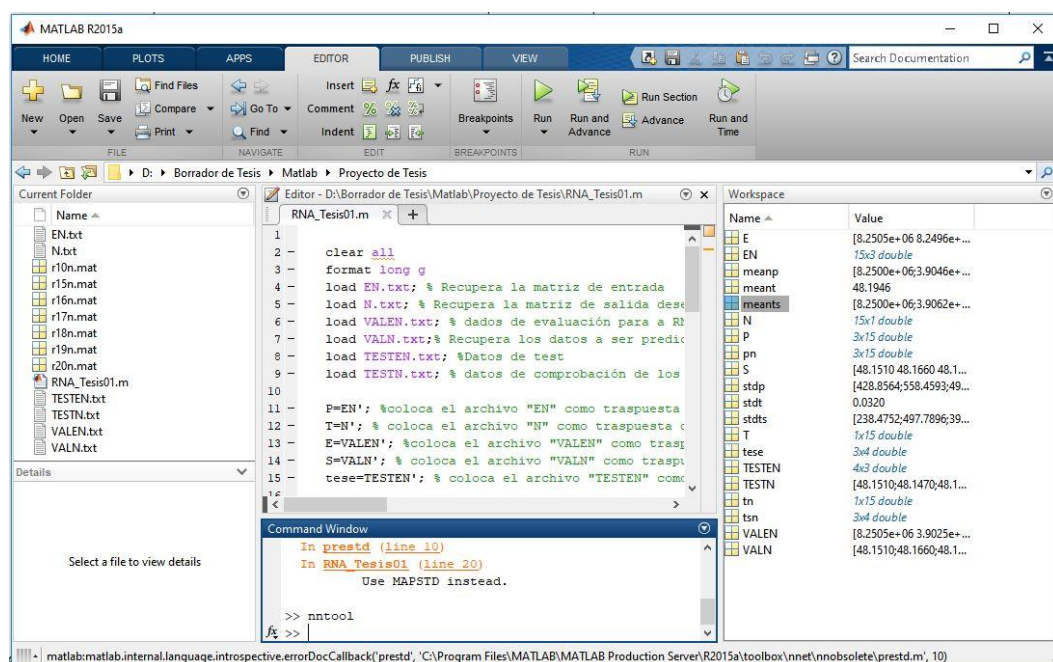


Figura N° 29: Entorno Matlab más escript para preprocesado de datos (Ver. de prueba)  
 Fuente: Elaboración propia



```
clear all
```

```
format long g
```

```
load EN.txt; % Recupera la matriz de entrada
```

```
load N.txt; % Recupera la matriz de salida deseada
```

```
load TESTEN.txt; % Datos de test
```

```
load TESTN.txt; % datos de comprobación de los puntos test
```

```
P=EN'; % coloca el archivo "EN" como traspuesta de la matriz en la variable "P" que contiene valores de norte, este y altura elipsoidal para los datos de entrenamiento
```

```
T=N'; % coloca el archivo "N" como traspuesta de la matriz en la variable "T" que contiene valores de ondulación geoidal para los datos de entrenamiento
```

```
tese=TESTEN'; % coloca el archivo "TESTEN" como traspuesta de la matriz en la variable "tese" que contiene valores de norte, este y altura elipsoidal para los datos de test (Carrion Sanchez, 2013)
```

Para crear, usar, importar, exportar datos, usar redes neuronales en matlab se utiliza la interfaz gráfica de usuario llamada “nntool”. El cual se activa al escribir al nntool en la barra de comandos, luego se abre una ventana de nombre Network / Data Manager (entrenador de datos y redes) (ver Figura N° 31)

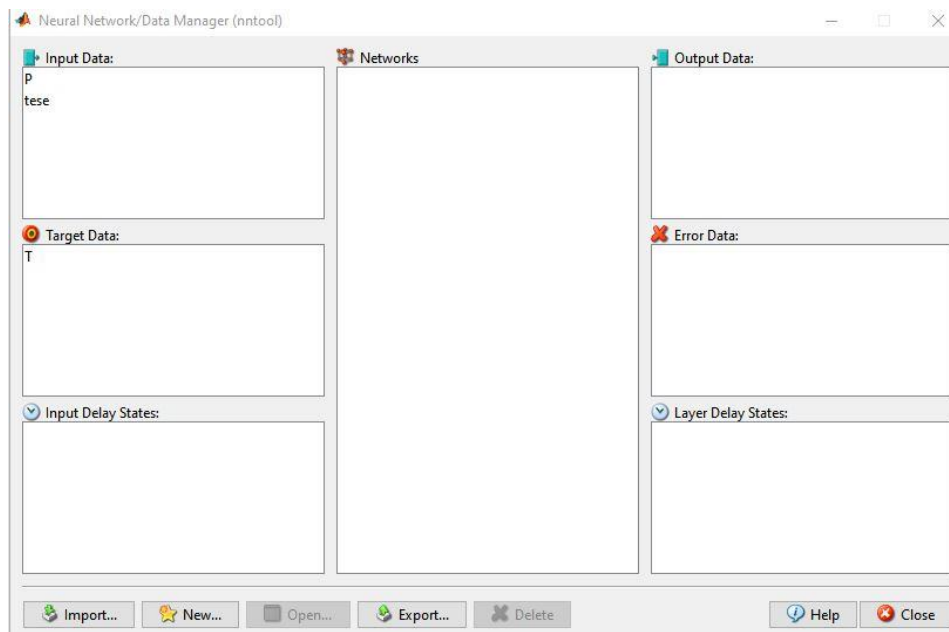


Figura N° 30: Toolbox Entrenador de Datos y Redes - Matlab 2015



Input Data: Almacena las matrices que se utilizara como datos de entrada, bien sea para entrenamiento, test, o funcionamiento, para ello importamos la matriz “P” que contiene los datos (norte, este, altura elipsoidal)

Target Data: Almacena las matrices que utilizara la red como salida para el entrenamiento, para nuestro proyecto es la matriz “T” que contiene los datos de (ondulaciones geoidales).

Networks: Espacio para construir las redes

Output Data: Son las salidas generadas por la red al ser entrenada, evaluada, simulada.

Error Data: Genera un vector de los errores ocurridos durante el entrenamiento de la red

Luego de ello le damos click en “New” para crear la red con sus respectivos parámetros.

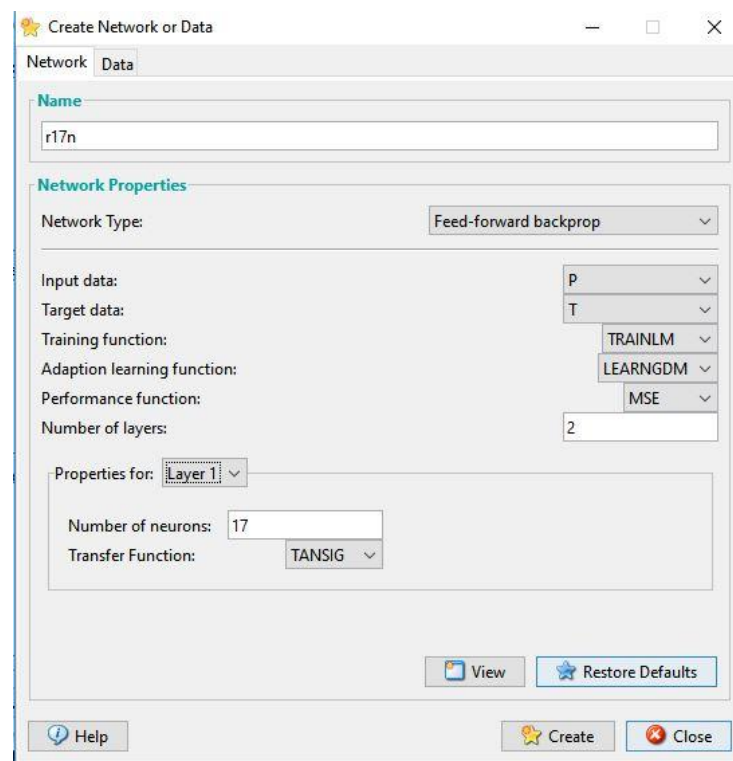


Figura N° 31: Configuración de la RNA

- Name : Nombre de la red definimos el nombre de la red “r17n”.
- Network Type : Es el tipo de red, para nuestro proyecto usaremos una red feed forward backpropagation, que es una red de retropropagación del error.
- Input data : Seleccionamos los datos de entrada matriz “P”
- Output data: Seleccionamos los datos de salida matriz “T”
- Training function : Función de entrenamiento Levenberr – Marquardt
- Adaption learnig function : Funcion de aprendizaje para adaptación, “Learnngdm Es el de gradiente con peso de momento y función de aprendizaje de sesgo”.
- Performance function : función de desempeño de la red calcula el error cuadrático medio (MSE) entre las matrices X e Y. X e Y pueden ser matrices de cualquier dimensión, pero deben ser del mismo tamaño y clase.
- Number of layers: Número de capas 02, (entrada y salida).
- Properties for layer: Determina las propiedades de la capa seleccionada.
- Number of neurons: Se refiere a la cantidad de neuronas de la capara oculta.
- Transfer function: Función de transferencia, la función de transferencia de la primera y segunda capa será del tipo tangente sigomidal (tansig), la capa de salida tendrá tantas neuronas como variables la función de transferencia será línea (purelin).
- Luego de haber terminado con la configuración de los parámetros de la RNA, seleccionamos la opción Create y en la sección de Networkc aparece nuestra RNA creada “r17n”, seleccionamos y le damos en Open.

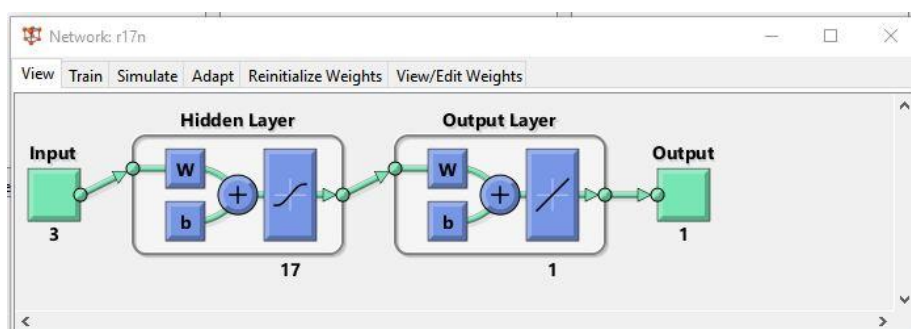


Figura N° 32: Red diseñada

En la Figura N° 33 se puede apreciar las 3 capas, 1 de entrada, 1 capa oculta con 17 neuronas y 1 capa de salida, y su correspondiente función de transferencia, además de aparecer además de ello se podrá visualizar los pesos sinápticos y sus umbrales, ver (Figura N° 34)

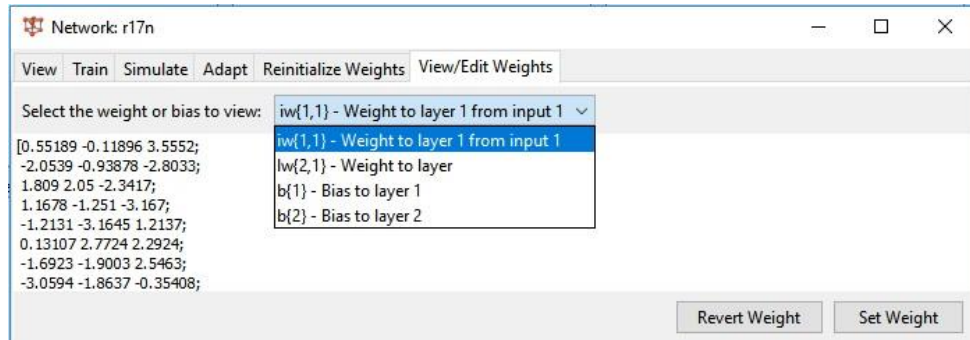


Figura N° 33: Pesos sinápticos y bias

IW: Input Weigth corresponde a la matriz de los pesos sinápticos entre la capa de entrada y la capa oculta.

b: bias corresponde al vector de umbrales de la capa de entrada

LW: Layer Weigth corresponde a los pesos sinápticos existentes entre la capa oculta y la capa de salida.

El proceso de entrenamiento consiste en lograr que la red aprenda mediante la determinación de los parámetros de entrenamiento que permitan un aprendizaje óptimo, algunos de estos parámetros de entrenamiento son:

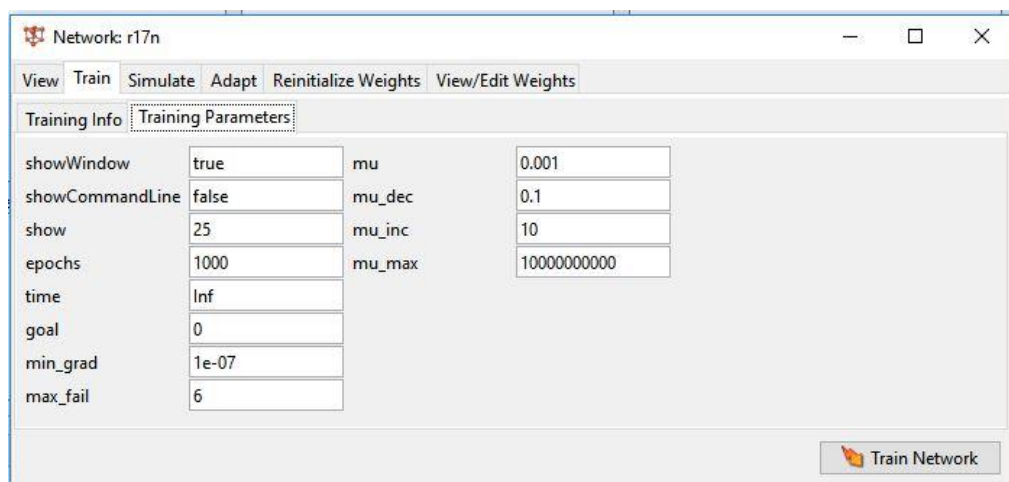


Figura N° 34: Parámetros de entrenamiento

Show: Intervalo de visualización de los resultados

Epochs: Corresponde al número de iteraciones

Time: máximo tiempo de entrenamiento en segundos

Goal: El error máximo permitido.

Min\_grad: Corresponde al valor mínimo del gradiente.

Max\_fail: Corresponde al número máximo de fallas permitido.

Mu: Corresponde al valor asociado a la tasa de aprendizaje final.

Mu\_inic: Corresponde al valor del incremento del “mu” durante el entrenamiento.

Mu\_dec: Corresponde al valor de decremento del “mu” durante el entrenamiento.

Mu\_max: Corresponde al valor máximo que puede alcanzar el “mu”.

Culminado las configuraciones de los parámetros de entrenamiento, en la pestaña “Train” opción Trainig Data (datos de entrenamiento), seleccionamos los datos de entrada y salida respectivamente. (Ver Figura N° 36). Luego de ello le damos click en Trainig Network (entrenar red).

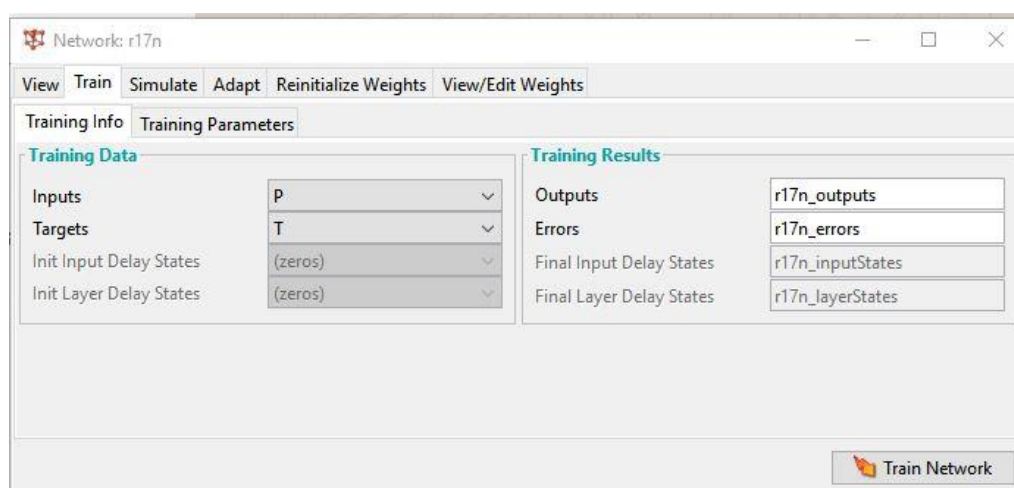


Figura N° 35: Entrenamiento de red

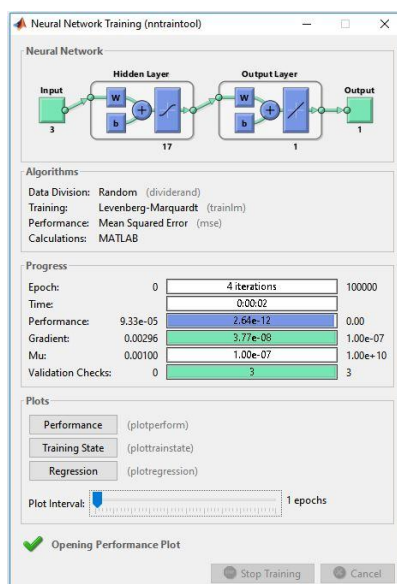


Figura N° 36: Reporte de Entrenamiento

Luego del entrenamiento verificamos errores de predicción, el propósito de la verificación es para decidir si realizamos el test de predicción con los 04 datos que estuvieron fuera del entrenamiento.

Tabla N°20  
*Ondulaciones conocidas y predecidas*

<b>CODIGO</b>	<b>Norte</b>	<b>Este</b>	<b>N</b>	<b>Predicción RNA</b>	<b>Error</b>
SP-001	8249347.112	390018.128	48.187	48.1832	0.0038
SP-002	8249466.756	390262.251	48.168	48.1795	-0.0115
SP-003	8249530.325	390604.469	48.192	48.1874	0.0046
SP-005	8249680.222	390355.907	48.166	48.1660	0.0000
SP-006	8249956.972	390394.252	48.187	48.1870	0.0000
SP-007	8250359.269	390768.038	48.203	48.2030	0.0000
SP-008	8250542.028	390549.556	48.218	48.2180	0.0000
SP-009	8250504.846	390247.625	48.262	48.2620	0.0000
SP-011	8249647.788	389817.184	48.215	48.2182	-0.0032
SP-012	8249863.725	390079.957	48.195	48.1950	0.0000
SP-013	8250645.628	389980.732	48.226	48.2260	0.0000
SP-014	8250475.265	389663.587	48.233	48.2330	0.0000
SP-016	8250002.484	391454.725	48.148	48.1480	0.0000
SP-018	8250242.273	391177.466	48.16	48.1600	0.0000
SP-019	8250175.069	391471.054	48.159	48.1590	0.0000

Predicción de RNA entrenada

Durante la etapa de entrenamiento de la red también se encuentra presente la matriz de pesos sinápticos (W) en donde sus valores son establecidos aleatoriamente, es aquí en donde realmente ocurre el proceso de aprendizaje cuando se ajustan estos parámetros, los cuales tienen por objeto aprender a reconocer características del espacio de entrada para la generalización de la red debido a que al momento de realizar las predicciones para un conjunto de datos que no estuvieron presentes dentro del proceso de entrenamiento de la red, presenten de manera certera el fenómeno que se quiere modelar.

Tabla N°21

*Pesos Sinápticos antes del entrenamiento*

0.55189	-0.11896	3.5552;
-2.0539	-0.93878	-2.8033;
1.809	2.05	-2.3417;
1.1678	-1.251	-3.167;
-1.2131	-3.1645	1.2137;
0.13107	2.7724	2.2924;
-1.6923	-1.9003	2.5463;
-3.0594	-1.8637	-0.35408;
-3.3292	-1.23	0.60174;
-2.3045	-2.4688	-1.2461;
-2.0942	-2.4382	1.6211;
-1.5607	2.653	-1.8667;
-0.5959	3.2854	1.3453;
-2.9181	0.48733	-2.0508;
2.3728	-2.5938	-0.77489;
3.0047	-1.7917	0.8486;
-0.10391	-1.6701	3.1872

Pesos entre la capa de entrada y la capa de salida

Tabla N°22

*Pesos Sinápticos después del entrenamiento*

-0.886523	-3.349628	-0.097577
-1.995506	2.826030	0.402014
-0.754761	0.238613	3.651765
-1.755361	-2.628002	1.986697
-1.026910	-0.180916	-3.428811
0.918415	0.707250	-3.493671

0.075798	-2.327266	-2.767336
-0.687152	2.842703	2.062629
3.249185	1.308973	-0.719668
-3.233022	-0.610142	-1.638628
-0.923966	3.382228	0.341676
-0.029848	-1.779448	3.222632
-2.726305	2.379049	-0.971466
-2.883150	-1.805070	0.677196
-2.128580	2.025567	-1.753624
-2.843903	-1.798297	-1.151914
1.929178	2.354618	-1.787758

Pesos entre la capa de entrada y la capa de salida

### 3.6.3 Predicción de ondulaciones geoidales en puntos de evaluación

Para la predicción de las ondulaciones geoidales se tomaron en consideración los residuales del entrenamiento para la predicción. (Ver Tabla N°20) y la curva de aprendizaje.




Figura N° 37: Curva de aprendizaje de la RNA



Tabla N°23  
*Predicción de ondulaciones geoidales en puntos de evaluación*

CODIGO	N	Predicción RNA	Error
SP-004	48.151	48.1972	-0.0462
SP-010	48.147	48.2357	-0.0887
SP-015	48.165	48.1793	-0.0143
SP-017	48.149	48.1505	-0.0015

Fuente: elaboración propia

### 3.6.4 Predicción de ondulaciones geoidales con coordenadas Norte y Este

Culminado el entrenamiento de las predicciones, ahora preparamos otra red neuronal como bajo el mismo procedimiento que el anterior, con la diferencia que ahora nuestra tendrá la arquitectura de 03 capas, 01 capa de entrada con 02 neuronas (norte y este), 01 capa oculta con 17 neuronas y 01 capa de salida (ondulaciones geoidales). Ver Figura N° 39.

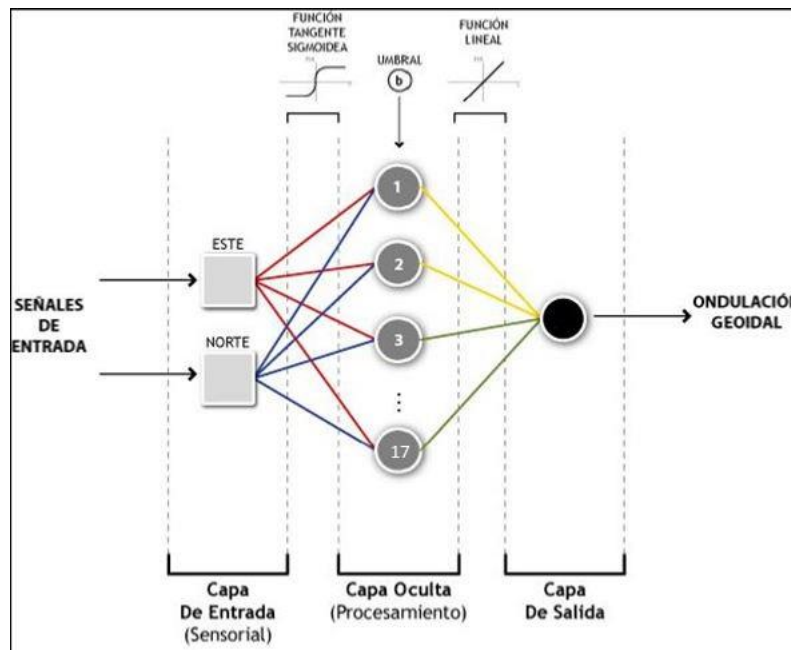


Figura N° 38: Arquitectura de RNA para entradas norte y este  
 Fuente: Elaboración propia.



Creamos la RNA para entradas norte y este, desde la barra de comando de matlab digitando “nntool”, el nombre de nuestra red es DEM, esta red estará encargada de predecir ondulaciones geoidales siendo alimentado solo de las coordenadas norte y este.

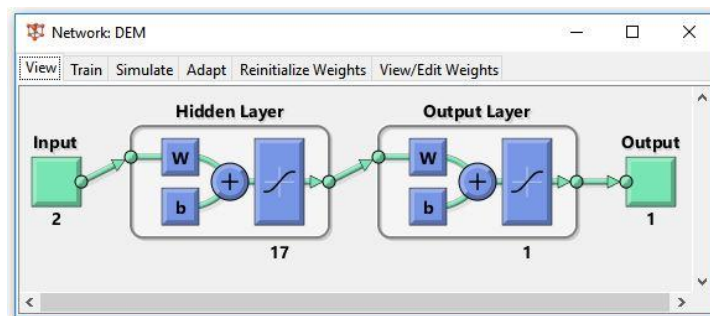


Figura N° 39: Arquitectura DEM

Las matrices de entrada (P) y salida (T) se detallan a continuación.

Tabla N°24

*Datos de capa de entreada para entrenamiento*

<b>CODIGO</b>	<b>Norte</b>	<b>Este</b>
SP-001	8249347.112	390018.128
SP-002	8249466.756	390262.251
SP-003	8249530.325	390604.469
SP-005	8249680.222	390355.907
SP-006	8249956.972	390394.252
SP-007	8250359.269	390768.038
SP-008	8250542.028	390549.556
SP-009	8250504.846	390247.625
SP-011	8249647.788	389817.184
SP-012	8249863.725	390079.957
SP-013	8250645.628	389980.732
SP-014	8250475.265	389663.587
SP-016	8250002.484	391454.725
SP-018	8250242.273	391177.466
SP-019	8250175.069	391471.054

Los datos serán ingresados en la matriz (P)

Tabla N°25  
*Datos de capa de salida*

CODIGO	N
SP-001	48.1872
SP-002	48.1684
SP-003	48.1917
SP-005	48.1664
SP-006	48.1867
SP-007	48.2031
SP-008	48.218
SP-009	48.2616
SP-011	48.2147
SP-012	48.1952
SP-013	48.2257
SP-014	48.2333
SP-016	48.1477
SP-018	48.1603
SP-019	48.1595

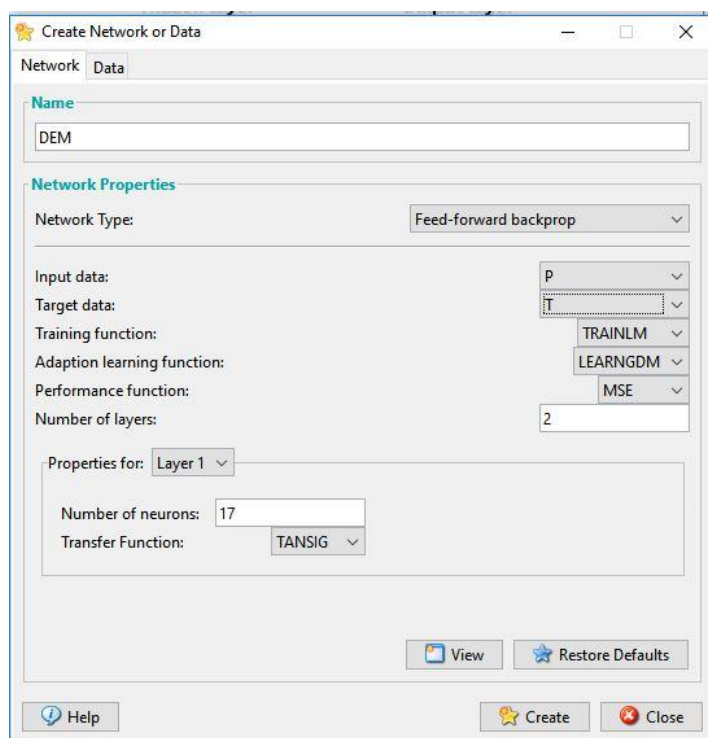


Figura N° 40: Parámetros de entrenamiento  
 Fuente: Elaboración propia.

El desempeño óptimo de la red neuronal de dos entradas [Este Norte] se consiguió durante el procedimiento de prueba error con una arquitectura de las mismas

características que la que se definió para la red con tres entradas (este norte y altura elipsoidal) , se estableció una red de tipo feedforward de tres capas interconectadas completamente y con 17 neuronas en la capa oculta (Figura N° 49); el algoritmo de aprendizaje usado fue el de Levenberg – Marquardt, para la capa oculta se definió una función de transferencia tangente sigmoidea y para la capa de salida una función de transferencia lineal. Para el entrenamiento de la red se fijó dentro del script de entrenamiento un número máximo de 500 épocas, como meta el valor de cero, y el tiempo de entrenamiento ilimitado. La función de error a minimizar por medio del algoritmo de entrenamiento es el error medio cuadrático (MSE).

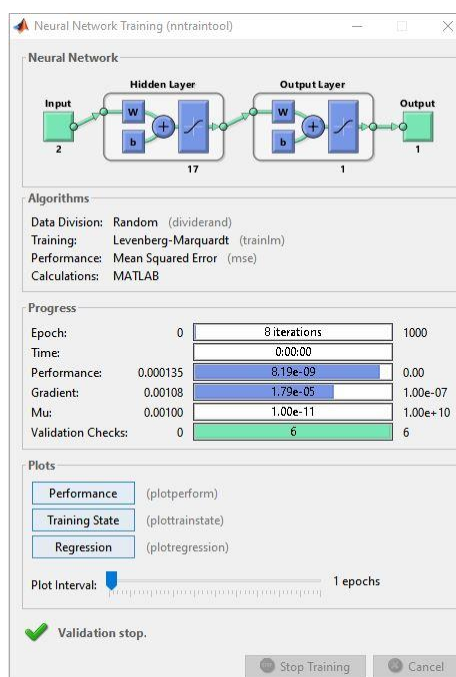


Figura N° 41: Reporte de entrenamiento  
Fuente: Elaboración propia.

Luego del entrenamiento la red reporta que después de 1000 iteraciones, en la octava iteración es en la que llega lo más próximo al valor esperado (ver Figura N° 42).

Tabla N°26

*Predicción de ondulaciones con entradas norte y este (Train)*

<b>Código</b>	<b>Norte</b>	<b>Este</b>	<b>N</b>	<b>Predicción</b>	<b>Error</b>
SP-001	8249347.112	390018.128	48.187	48.1847	0.002
SP-002	8249466.756	390262.251	48.168	48.1772	-0.009
SP-003	8249530.325	390604.469	48.192	48.1868	0.005
SP-005	8249680.222	390355.907	48.166	48.1714	-0.005
SP-006	8249956.972	390394.252	48.187	48.1855	0.001
SP-007	8250359.269	390768.038	48.203	48.1981	0.005
SP-008	8250542.028	390549.556	48.218	48.2193	-0.001
SP-009	8250504.846	390247.625	48.262	48.2532	0.008
SP-011	8249647.788	389817.184	48.215	48.2124	0.002
SP-012	8249863.725	390079.957	48.195	48.201	-0.006
SP-013	8250645.628	389980.732	48.226	48.2531	-0.027
SP-014	8250475.265	389663.587	48.233	48.2344	-0.001
SP-016	8250002.484	391454.725	48.148	48.1562	-0.009
SP-018	8250242.273	391177.466	48.160	48.1605	0.000
SP-019	8250175.069	391471.054	48.159	48.1564	0.003

Tabla N°27

*Predicción de ondulaciones con entradas norte y este (Test)*

<b>CODIGO</b>	<b>N</b>	<b>PREDICCION</b>	<b>ERROR</b>
SP-004	48.151	48.1560	-0.005
SP-010	48.147	48.2324	-0.086
SP-015	48.165	48.1614	0.004
SP-017	48.149	48.1513	-0.002

Terminado el entrenamiento es necesario realizar un grillado de coordenadas norte y este, proceso que se realizó en el software autodesk civil 3d, generando una malla de 50m x 50m, de esta manera conseguimos 1347 puntos, los cuales serán ingresados a la red neuronal DEM, para su procesamiento de predicción para cada uno de los puntos (ver Figura N° 43).

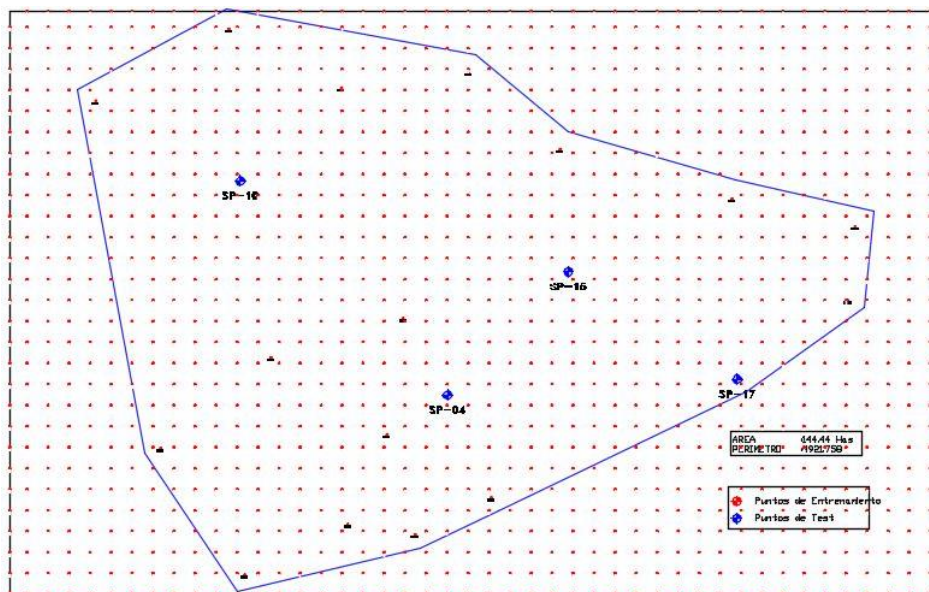


Figura N° 42: Generación de puntos norte y este  
Fuente: Elaboración propia.

### 3.5.5 Elaboración de modelo digital de elevaciones de las ondulaciones geoidales predecidas

Determinadas las ondulaciones, recurrimos al software Golden Surfer 13.0, para el modelamiento respectivo.

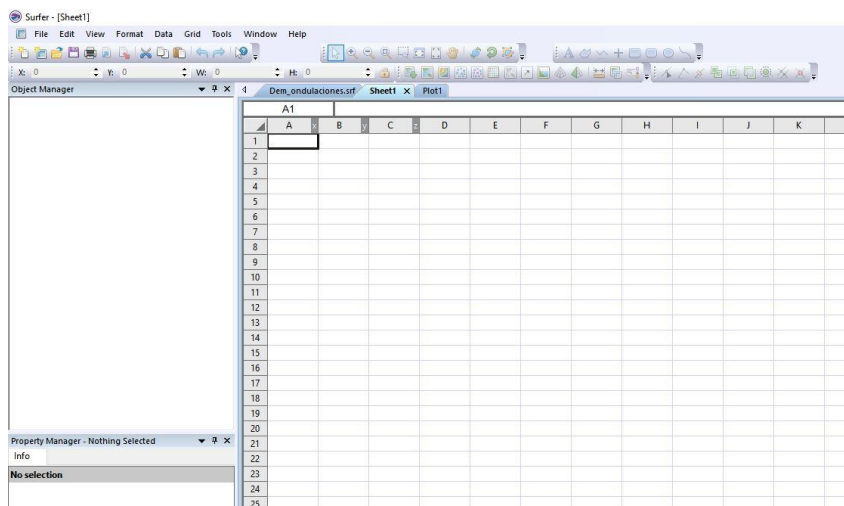
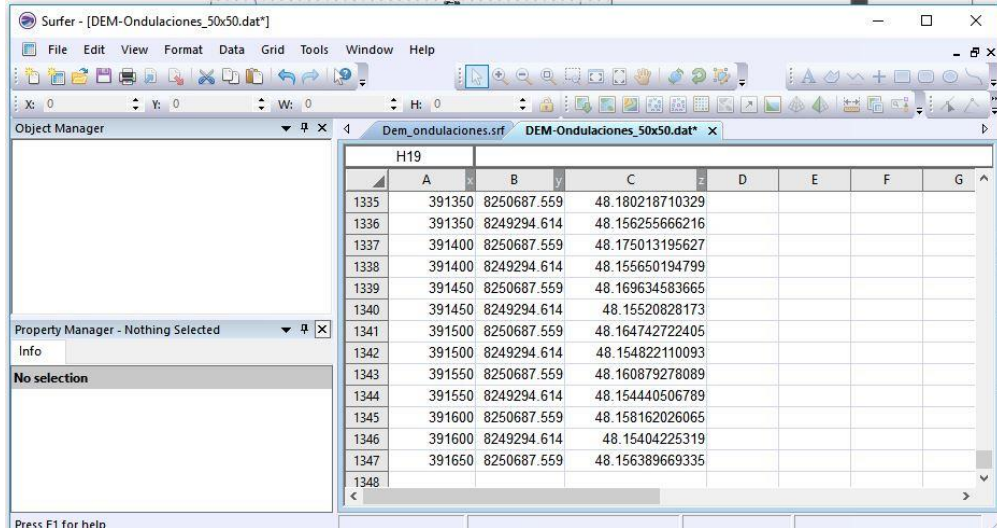


Figura N° 43: Plataforma Golden Surfer 13 (Ver. Prueba)  
Fuente: Elaboración propia.

Insertamos los puntos generados en civil 3d, complementamos las ondulaciones predecidas y las cargamos a la libreta de Surfer 13, para posteriormente generar los

mapas. En la columna “A” se visualiza las coordenadas este, norte y ondulación geoidal (predicciones). La totalidad de puntos son 1347 puntos.



	A	B	C	D	E	F	G
1335	391350	8250687.559	48.180218710329				
1336	391350	8249294.614	48.156255666216				
1337	391400	8250687.559	48.175013195627				
1338	391400	8249294.614	48.155650194799				
1339	391450	8250687.559	48.169634583665				
1340	391450	8249294.614	48.15520828173				
1341	391500	8250687.559	48.164742722405				
1342	391500	8249294.614	48.154822110093				
1343	391550	8250687.559	48.160879278089				
1344	391550	8249294.614	48.154440506789				
1345	391600	8250687.559	48.158162026065				
1346	391600	8249294.614	48.15404225319				
1347	391650	8250687.559	48.156389669335				
1348							

Figura N° 44: Datos para modelamiento  
Fuente: Elaboración propia.

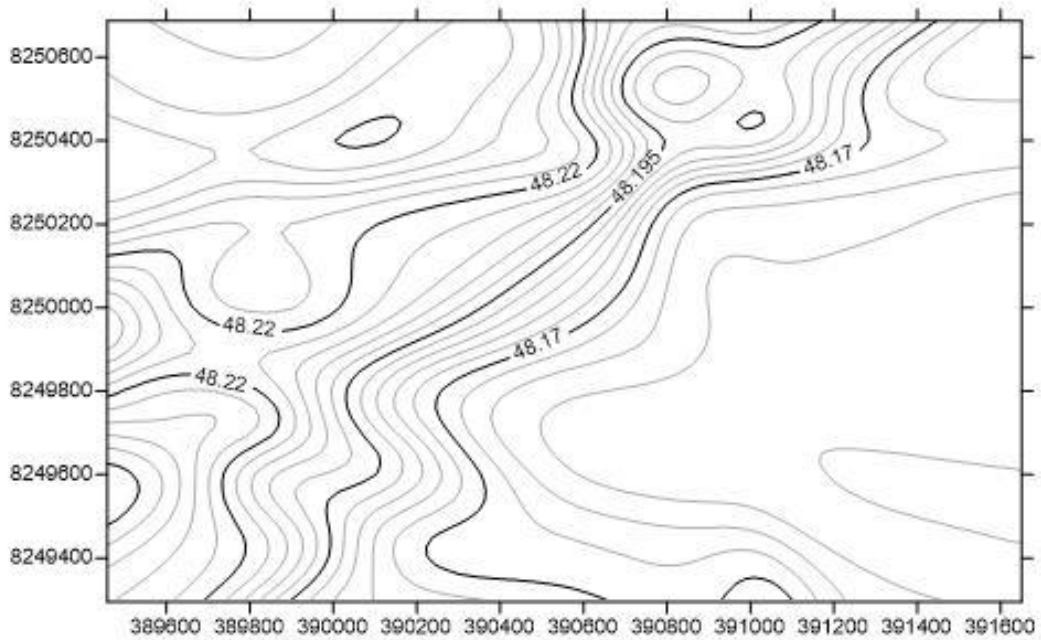


Figura N° 45: Plano planta de ondulaciones  
Fuente: Elaboración propia.






Figura N° 46: Gráfica de elevaciones  
Fuente: Elaboración propia.

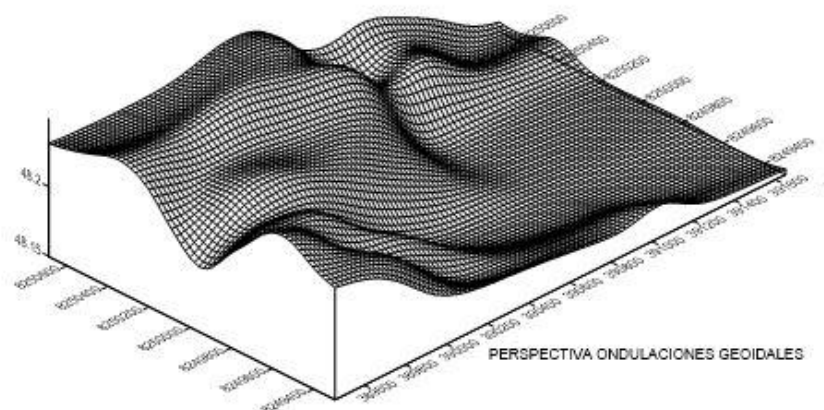


Figura N° 47: Plano en perspectiva  
Fuente: Elaboración propia




Figura N° 48: Modelo 3D de las ondulaciones geoidales por el método RNA  
Fuente: Elaboración propia

## IV. RESULTADOS Y DISCUSIÓN

### 4.1 Método de investigación

La investigación es experimental – descriptivo, con recolección de datos de manera directa.

### 4.2 Población y muestra

La población de la presente investigación son datos dispersos de observación GNSS, y nivelación geométrica ubicados en la zona norte del sector urbano de la ciudad de Puno.

### 4.3 Comparación de resultados

Durante el proceso de entrenamiento de la red neuronal se trabajó con 02 grupos de datos que forman parte del entrenamiento de la red neuronal artificial para predecir la ondulación geoidal local. El primer grupo corresponde a los datos del proceso de aprendizaje de la RNA conformada por coordenadas norte, este, alturas elipsoidales y/o ondulaciones geoidales. El segundo grupo corresponde a datos de evaluación (datos predecidos).

#### 4.3.1 Datos experimentales

Resultados de precisiones GNSS, estos valores se consideran tolerables bajo las normas las especificaciones técnicas de posicionamiento GNSS establecido por el Instituto Geográfico Nacional (IGN).

Tabla N°28

*Precisiones de posicionamiento GNSS*

De	A	Tipo de solución	Prec. H. (Metro)	Prec. V. (Metro)
PN01	BASE-B	Fija	0.004	0.006
BASE-B	SP-001	Fija	0.005	0.009



BASE-B	SP-003	Fija	0.004	0.005
BASE-B	SP-004	Fija	0.003	0.007
BASE-B	SP-005	Fija	0.002	0.005
BASE-B	SP-006	Fija	0.002	0.005
BASE-B	SP-007	Fija	0.009	0.010
BASE-B	SP-008	Fija	0.004	0.006
BASE-B	SP-009	Fija	0.006	0.013
BASE-B	SP-010	Fija	0.003	0.006
BASE-B	SP-011	Fija	0.005	0.010
BASE-B	SP-013	Fija	0.004	0.008
BASE-B	SP-012	Fija	0.005	0.006
BASE-B	SP-014	Fija	0.003	0.009
BASE-B	SP-015	Fija	0.002	0.007
BASE-B	SP-016	Fija	0.006	0.008
BASE-B	SP-017	Fija	0.004	0.007
BASE-B	SP-018	Fija	0.004	0.008
BASE-B	SP-019	Fija	0.004	0.010
BASE-B	SP-002	Fija	0.004	0.004

Tabla N°29

*Datos de Nivelación y residuales*

<b>ID</b>	<b>COTA DE CAMPO</b>	<b>COTA AJUSTADA (h)</b>	<b>RESIDUAL</b>
SP01	3828.412	3828.4108	-0.0012
SP02	3823.7402	3823.7388	-0.0014
SP02	3854.1836	3854.1836	0.0000
SP03	3840.3175	3840.3143	-0.0032
SP04	3856.2608	3856.2605	-0.0003
SP05	3900.6464	3900.6456	-0.0008
SP06	3921.2357	3921.2343	-0.0014
SP07	3822.7053	3822.7039	-0.0014
SP08	3833.1706	3833.1690	-0.0016
SP09	3853.921	3853.9194	-0.0016
SP10	3891.6268	3891.6245	-0.0023
SP11	3839.1288	3839.1273	-0.0015
SP12	3953.7431	3953.7418	-0.0013
SP13	3923.5139	3923.5113	-0.0026
SP14	3948.0211	3948.0177	-0.0034
SP15	3897.1678	3897.1669	-0.0009
SP16	3812.1879	3812.1871	-0.0008
SP17	3812.0596	3812.0583	-0.0013
SP18	3815.7905	3815.7887	-0.0018
SP19	3832.8608	3832.8595	-0.0013

### 4.3.2 Datos descriptivos

#### 4.3.2.1 Predicción de ondulaciones geoidales

En esta sección se presentan las predicciones de las 04 ondulaciones geoidales que fueron obtenidas después de realizarse el entrenamiento de la red utilizando los 15 datos de entrada que siguieron los parámetros indicados en la sección 3.6.2.

La Tabla N°30 muestra en la primera columna el nombre de los puntos de evaluación (test) , en la segunda columna la ondulación verdadera determinada mediante GNSS/nivelación geométrica, en la tercera columna la predicción de las ondulación geoidales a partir del entrenamiento de una red neuronal artificial con entradas (Norte, Este, altura Elipsoidal), en la cuarta columna las diferencias existentes entre las ondulaciones obtenidas por el método directo (GNSS/Nivelación) y las predecidas por la RNA (r17n).

Tabla N°30

*Comparación de ondulaciones geoidales obtenidas a través de GNSS/Nivelación y RNA con entradas (norte, este, altura elipsoidal).*

<b>CODIGO</b>	<b>N</b>	<b>Predicción RNA</b>	<b>Error</b>
SP-004	48.151	48.1972	-0.0462
SP-010	48.147	48.2357	-0.0887
SP-015	48.165	48.1793	-0.0143
SP-017	48.149	48.1505	-0.0015

Donde la media para las ondulaciones (N) conocidas es:

$$\bar{x}_c = \frac{\sum_{i=1}^n c_i}{n} \Rightarrow \frac{192.612}{4} = 48.153$$

y su desviación estándar es

$$s_c = \sqrt{\frac{\sum_{i=1}^n (c_i - \bar{x}_c)^2}{n - 1}} = 0.00816$$

Donde la media para las predicciones es:

$$\bar{x}_c = \frac{\sum_{i=1}^n c_i}{n} \Rightarrow \frac{192.7627}{4} = 48.191$$

y su desviación estándar es

$$s_c = \sqrt{\frac{\sum_{i=1}^n (c_i - \bar{x}_c)^2}{n - 1}} = 0.03565$$

Tabla N°31

*Estadísticos de ondulaciones geoidales obtenidas a través de RNA con entrada (Norte, Este y altura elipsoidal).*

Estadísticos RNA(N E h)		
N	Válido	4
	Perdidos	0
	Error estándar de la media	,0178261
	Desviación estándar	,0356522
	Varianza	,001
	Mínimo	48,1505
	Máximo	48,2357

A través de la Tabla N°31 se observa que la predicción de ondulaciones por método de RNA con entrada norte, este y altura elipsoidal, concluye en una desviación estándar de 3.56cm, se puede indicar que las predicciones de cualquier punto dentro del área de estudio tendrán ésta precisión.

La Tabla N°32 muestra en la primera columna el nombre de los puntos de evaluación (test), en la segunda columna la ondulación verdadera, determinada mediante nivelación geométrica, en la tercera columna la predicción de las ondulación a partir del entrenamiento de una red neuronal artificial con entradas (Norte y Este), en la cuarta columna las diferencias existentes entre las ondulaciones obtenidas por el GNSS/Nivelación.

Tabla N°32

*Comparación de ondulaciones geoidales obtenidas a través de GNSS/Nivelación y RNA obtenida con entradas (Norte y Este).*

CODIGO	N	PREDICCIÓN	ERROR
SP-004	48.151	48.1560	-0.005
SP-010	48.147	48.2324	-0.086
SP-015	48.165	48.1614	0.004
SP-017	48.149	48.1513	-0.002

Donde la media para las predicciones es:

$$\bar{x}_c = \frac{\sum_{i=1}^n c_i}{n} \Rightarrow \frac{192.701}{4} = 48.1753$$

y su desviación estándar es

$$s_c = \sqrt{\frac{\sum_{i=1}^n (c_i - \bar{x}_c)^2}{n-1}} = 0.03831$$

Tabla N°33

*Estadísticos de ondulaciones geoidales obtenidas a través de RNA con entrada (Norte y Este).*

Estadísticos RNA(N E)		
N	Válido	4
	Perdidos	0
Error estándar de la media		,019153
Desviación estándar		,038306
Varianza		,001
Mínimo		48,151
Máximo		48,232

Fuente: IBM SPSS

A través de la Tabla N°33 se observa que la predicción de ondulaciones por método de RNA con entrada norte y este, concluye en una desviación estándar de 0.03831m, se puede indicar que las predicciones de cualquier punto dentro del área de estudio tendrán ésta precisión.

Los errores que se obtienen en los puntos de evaluación empleando redes neuronales con entradas norte, este y altura elipsoidal no sobrepasan los 0.03565 m y para la red con entradas con norte y este de la misma forma no sobrepasan los 0.03831m.

#### 4.4 Prueba $t$ para dos muestras independientes RNA “NEh”

En esta parte haremos una comparación entre las ondulaciones geoidales conocidas (N) y las ondulaciones predecidas por las RNA con entradas (norte, este, altura elipsoidal)

Dónde:

H1 = Existe una diferencia significativa entre la media de ondulaciones geoidales obtenidas mediante redes neuronales artificiales con entradas (*norte, este, altura elipsoidal*).

Ho = No Existe una diferencia significativa entre la media de ondulaciones geoidales obtenidas mediante redes neuronales artificiales con entradas (*norte, este, altura elipsoidal*).

$$T = \frac{(Y_1 - Y_2)}{S}$$

$$T = \frac{48.153 - 48.191}{0.018286}$$

$$T = -2.078095$$

La varianza común se calcula según la varianza agrupada.

$$S_{Y_1-Y_2} = \sqrt{\frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{n_1 + n_2 - 2}}$$

$$S_{Y_1-Y_2} = \sqrt{\frac{(4 - 1)0.00816^2 + (4 - 1)0.03565^2}{4 + 4 - 2}}$$

$$S_{Y_1-Y_2} = 0.02586$$

La desviación estándar de  $Y_1 - Y_2$  se estima mediante:

$$S = S_{Y_1 - Y_2} \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$$

$$S = 0.02586 \sqrt{\frac{1}{4} + \frac{1}{4}}$$

$$S = 0.018286$$

Dónde:

$Y_1$  y  $Y_2$  : Medias de las muestras 1 y 2


$S_1$  y  $S_2$  : Desviación estándar de las muestras 1 y 2

$n_1$  y  $n_2$  : Tamaño de la muestra 1 y 2

T se distribuye con t de student con  $n_1 + n_2 - 2$  grados de libertad.

**Interpretación:**

**Tabla de cuantiles de la distribución t de Student**



(a) El área de las dos colas está sombreada en la figura.  
 (b) Si  $H_A$  es direccional, las cabeceras de las columnas deben ser divididas por 2 cuando se acota el P-valor.

gl	ÁREA DE DOS COLAS						
	0,20	0,10	0,05	0,02	0,01	0,001	0,0001
1	3,078	6,314	12,706	31,821	63,657	636,619	6366,198
2	1,886	2,920	4,303	6,695	9,925	31,598	99,992
3	1,638	2,353	3,182	4,541	5,841	12,924	28,000
4	1,533	2,132	2,776	3,747	4,604	8,610	15,544
5	1,476	2,015	2,571	3,365	4,032	6,869	11,178
6	1,440	1,943	2,447	3,143	3,707	5,959	9,082
7	1,415	1,895	2,365	2,998	3,499	5,408	7,885

Figura N°49 Tabla de distribución t

$t_{0,05} = 2.447$ ; también llamado **t crítico**. (Ver Figura N°48)

Si "**T=-2.078095**" es menor que el valor crítico, entonces se encuentra dentro del área de no rechazo de la hipótesis nula, por el cual no existe una diferencia significativa

entre la media de ondulaciones geoidales obtenidas mediante redes neuronales artificiales con entradas (*norte, este, altura elipsoidal*).

Por lo tanto se rechaza la hipótesis nula y se acepta la hipótesis alterna.

#### 4.5 Prueba *t* para dos muestras independientes RNA “NE”

En esta parte haremos una comparación entre las ondulaciones geoidales conocidas (N) y las ondulaciones predecidas por las RNA con entradas (*norte, este*).

Dónde:

H1 = Existe una diferencia significativa entre la media de ondulaciones geoidales obtenidas mediante redes neuronales artificiales con entradas (*norte, este*).

Ho = No Existe una diferencia significativa entre la media de ondulaciones geoidales obtenidas mediante redes neuronales artificiales con entradas (*norte, este*).

$$T = \frac{(Y_1 - Y_2)}{S}$$

$$T = \frac{48.153 - 48.1753}{0.019585}$$

$$T = -1.138644$$

La varianza común se calcula según la varianza agrupada.

$$S_{Y_1-Y_2} = \sqrt{\frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{n_1 + n_2 - 2}}$$

$$S_{Y_1-Y_2} = \sqrt{\frac{(4 - 1)0.00816^2 + (4 - 1)0.03831^2}{4 + 4 - 2}}$$

$$S_{Y_1-Y_2} = 0.027697$$

La desviación estándar de  $Y_1 - Y_2$  se estima mediante:

$$S = S_{Y_1-Y_2} \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$$

$$S = 0.027697 \sqrt{\frac{1}{4} + \frac{1}{4}}$$

$$S = 0.019585$$

Dónde:

$Y_1$  y  $Y_2$  : Medias de las muestras 1 y 2

$S_1$  y  $S_2$  : Desviación estándar de las muestras 1 y 2

$n_1$  y  $n_2$  : Tamaño de la muestra 1 y 2

T se distribuye con t de student con  $n_1 + n_2 - 2$  grados de libertad.

Interpretación:

$t_{0,05} = 2.447$ ; también llamado **t** crítico. (Ver *Figura N°48*)

Si “**T=-1.138644**” es menor que el valor crítico, entonces se encuentra dentro del área de no rechazo de la hipótesis nula, por el cual no existe una diferencia significativa entre la media de ondulaciones geoidales obtenidas mediante redes neuronales artificiales con entradas (*norte, este*).

Por lo tanto se rechaza la hipótesis nula y se acepta la hipótesis alterna.



## CONCLUSIONES

### Del objetivo General

1. Con el método GNSS/ nivelación y redes neuronales artificiales con entrada (norte y este) fue posible obtener un modelo local que representa las ondulaciones geoidales con precisiones menor a 0.03831 m. dicha precisión se determinó luego de hacer la prueba  $t$  para dos muestras independientes, comparando las ondulaciones geoidales obtenidas mediante la red neuronal artificial con entradas (norte, este) y las obtenidas mediante nivelación geométrica (ondulaciones conocidas) según se detalla en la *Tabla N° 32*.

### De los objetivos específicos

1. Las precisiones de ondulaciones geoidales obtenidas por la Red Neuronal Artificial, con entradas (norte, este, altura elipsoidal) y RNA con entradas (norte y este) si son aplicables dentro del perímetro de proyecto, el primer modelo con precisión según desviación estándar de 0.03565m y el segundo con 0.03831m, Debido a que según la prueba  $t$ , ambas tienen la capacidad predictiva dentro del área de no rechazo de la hipótesis nula.
2. Para realizar el comparativo nos apoyaremos en el siguiente cuadro resumido:

Cuadro Comparativo de las Ondulaciones Geoidales									
Ondulaciones Geoidales (m)						ERRORES DE APROXIMACION A "H"			
ID	N	RNA (N.E.h.)	RNA (N.E.)	EGM96 (N)	EGM08 (N)	RNA (N.E.h.)	RNA (N.E.)	EGM96 (N)	EGM08 (N)
SP-004	48.151	48.197	48.156	45.422	45.709	-0.046	-0.005	2.729	2.442
SP-010	48.147	48.236	48.232	45.423	45.713	-0.039	-0.085	2.728	2.438
SP-015	48.165	48.179	48.161	45.419	45.722	-0.014	0.004	2.732	2.429
SP-017	48.149	48.151	48.151	45.419	45.722	-0.002	-0.002	2.732	2.429
<b>Media</b>	48.153	48.191	48.175	45.421	45.716			2.730	2.435
<b>D. Estd.</b>	0.00816	0.03565	0.03831	0.002	0.007	0.03565	0.03831	0.002	0.007

Fuente: Elaboración propia.

ID: Indica el código de los puntos de test, puntos que si bien recordamos no fueron parte del proceso de entrenamiento y aprendizaje de la RNA.

N: Ondulaciones geoidales conocidas obtenidas mediante nivelación geométrica.

RNA (N.E.h.): Ondulaciones predecidas por la RNA con entradas norte, este y altura elipsoidal.

RNA (N.E.): Ondulaciones predecidas por la RNA con entradas norte, este.

EGM96 (N): Ondulaciones geoidales obtenidas realizando la diferencia de la altura elipsoidal de cada punto menos la altura geoidal del modelo EGM96.

EGM08 (N): Ondulaciones geoidales obtenidas realizando la diferencia de la altura elipsoidal de cada punto menos la altura geoidal del modelo EGM08.

De donde se determina que la desviación estándar de los modelos mundiales (EGM96 (N) y EGM08 (N)) es mucho mayor a los obtenidos por las RNA, pero el error de aproximación a la altura ortométrica real referida al nivel medio del mar con punto inicial en Punta Callao en tiene una media de 2.730 para el EGM96 y 2.435 para el EGM08. Lo que significa que las ondulaciones obtenidas por las RNA, son más próximos a las alturas conocidas obtenidas mediante nivelación geométrica, en consecuencia si le restamos las ondulaciones obtenidas por RNA, a cualquier altura elipsoidal dentro del perímetro de proyecto obtendremos una altura ortométrica con precisiones de 0.03831m.

## RECOMENDACIONES

Para realizar un entrenamiento con redes neuronales es necesario contar con una cantidad suficiente de datos que se encuentren distribuidos uniformemente en el área de estudio y tengan una buena representatividad de lo que se desea modelar, para que no exista inconvenientes cuando se realice la interpolación de los mismos y se pueda obtener buenas predicciones.

Se debe investigar métodos en los que se pueda determinar cuántas neuronas debe contener la capa oculta, así como cuantas capas ocultas debe tener una red neuronal artificial ya que a través de una buena topología de red se puede obtener una mejor generalización o aprendizaje de la red neuronal artificial.

Los datos de posicionamiento geodésico y nivelación deben de ser lo más preciso posible, se recomienda usar una nivelación de alta precisión. Ya que de ello depende el desempeño y el aprendizaje de la red neuronal artificial.

## REFERENCIAS

- Administración Nacional de la Aeronáutica y del Espacio NASA. (2016). *exploración del espacio, administrar el movimiento de satélites artificiales en órbita, de alguna manera buscar vida fuera de la tierra, observar los riesgos de la tierra y crear mapas universales exactos además de predecir los movimientos de los astros*. Obtenido de <https://www.nasa.gov/>
- Ayala Ramírez, A., & Hasbun Bardales, M. M. (2012). *Aplicaciones y uso de la tecnología de GPS diferencial de doble frecuencia con precisión centimétrica en el área de levantamiento y replanteo topográfico georreferenciado*, Universidad de El Salvador. Salvador, Universidad de el Salvador.
- Basogain Olabe, X. (2008). *Redes Neuronales Artificiales y sus Aplicaciones*. Bilbao.
- Carrion Sanchez, J. L. (2013). *Generación de una malla de ondulaciones geoidales por el método GPS/Nivelación y redes neuronales artificiales*. La Plata.
- Carvacho B. , L. (s.f.). *Proyecciones cartográficas y UTM, pontificia universidad católica de Chile*. Obtenido de :
- [http://slideplayer.es/slide/1120575/#.V1mQYcGKDfc.google\\_plusone\\_share](http://slideplayer.es/slide/1120575/#.V1mQYcGKDfc.google_plusone_share)
- Cmglee, Geo Swan. (2016). *Comparación de los sistemas GPS, GLONASS, Galileo y Compass (órbita terrestre media) órbitas satelitales del sistema de navegación con la Estación Espacial Internacional*. Obtenido de [https://upload.wikimedia.org/wikipedia/commons/b/b4/Comparison\\_satellite\\_navigation\\_orbits.svg](https://upload.wikimedia.org/wikipedia/commons/b/b4/Comparison_satellite_navigation_orbits.svg)
- Efemerides. (2013). *Efemerides astronomicas*. Obtenido de <http://efemeridesastronomicas.dyndns.org>.
- Fernandez Coppel , I. A. (2001). *Localizaciones geográficas y la proyección UTM*. Universidad de Valladolid. España.
- Haykin, S. S. (2001). *Redes Neurais*. Bookman Companhia.
- Hebb, D. (1949). *The Organization of Behavior a Neuropsychological Theory*. New Nork: McGell Univerity.

- Hofman, B., & Helmut Moritz, W. (2005). *Physical Geodesy*. Austria: Graz.
- [https://es.wikipedia.org/wiki/Red\\_neuronal\\_artificial](https://es.wikipedia.org/wiki/Red_neuronal_artificial). (2017).
- Instituto Nacional Geográfico de España IGN. (2016). *Centro nacional de información geográfica*. Obtenido de Sistema GPS: <http://www.ign.es/ign/main/index.do>, <https://www.ign.es/ign/resources/acercaDe/aig/D.pdf>
- Instituto Nacional Geográfico del Perú IGN. (2016). *Ente rector de la cartografía nacional*. Obtenido de <http://www.ign.gob.pe/index.php>
- Isasi Viñueta Pedro, G. L. (2004). *Redes Neuronales Artificiales un enfoque práctico*. España: Prentice Hall.
- Jose Luis Carrion, D. d. (2013). *Interpolación de la ondulación geoidal geométrica mediante un ared neuronal artificial multicapa*. La Plata, Buenos Aires, Argentina.
- Lapaine , M., & Usery , L. (2015). *Proyecciones cartográficas y sistemas de referencia*. EE.UU.
- Martin, B. (2001). *Redes Neuronales y Sistemas Borrosos*. Alfa Omega.
- Mendoza Dueñas, J. (2012). *Técnicas modernas*. Perú.
- Peñañiel , J., & Zayas , J. (2001). *fundamentos del sistema GPS y aplicaciones en la topografía, Ilustre Colegio Oficial de Ingeniería Geomática y Topográfica*. España.
- Santos del Riego , A., & Alvares Penin , M. (2002). *Desarrollo de un Sistema Gestor de Rutas de Posicionamiento Global por Satélite, Universidad de Coruña*. España.
- Silva, M. A. (2010). *Predicción de ondulaciones geoidales a través de una red neuronal artificial en un área del distrito metropolitano de Quito*. SANGOLQUÍ – ECUADOR.
- Sistema de referencia terrestre internacional convencional ITRF. (2016). *International Terrestrial Reference Frame* . Obtenido de <http://itrf.ensg.ign.fr/>

Wagner Carrupt Machado, A. C. (2016). El uso de redes neuronales en la interpolación de anomalías de gravedad – aplicación en el cálculo del modelo geoidal en Santa Catarina - Brasil. *Geoacta*.

## GLOSARIO

**Altura al nivel medio del mar.** También denominado nivel cero, es la superficie de referencia para medir altitudes. Este nivel medio es una mejor aproximación a la forma real de la Tierra, la cual a su vez depende de las irregularidades en el campo gravitatorio terrestre, que alteran su posición.

**Altura elipsoidal ( $h$ ).** Medida a lo largo de la normal elipsoidal, es la distancia entre la superficie del elipsoide y el punto de medición. La magnitud y dirección de este vector dependen del elipsoide empleado.

**Altura nivelada.** Es la altura referida al nivel medio del mar determinado por los mareógrafos en una determinada localización geográfica. En el caso del Perú se encuentra en Punta Callao.

**Altura ortométrica ( $H$ ).** Distancia vertical existente entre la superficie del geoide y la superficie de la Tierra, la cual es medida a lo largo de la línea de la plomada. Esta distancia no es una línea recta sino que tiene una ligera curvatura que es tangencial a la dirección de la gravedad en cualquier punto, ya que la dirección de la gravedad varía, dependiendo de las características de densidad local y de la distribución de las masas en el interior de la Tierra. En la práctica la altura ortométrica puede ser considerada como altura sobre el nivel medio del mar.

**Aprendizaje.** Es el proceso a través del cual se adquieren nuevas habilidades, destrezas, conocimientos, conductas o valores como resultado del estudio, la experiencia, la instrucción y la observación. Este proceso puede ser analizado desde distintas perspectivas, por lo que existen distintas teorías del aprendizaje. El aprendizaje es una de las funciones mentales más importantes en humanos, animales y sistemas artificiales.

El aprendizaje en una red neuronal artificial consiste en la determinación de los valores precisos de los pesos para todas sus conexiones, que la capacite para la resolución eficiente de un problema.

**Backpropagation.** Algoritmo también denominado de retropropagación del error, propaga el error de manera inversa al funcionamiento normal de la red en donde la información recorre de izquierda a derecha, es decir, desde la capa de salida a la de entrada en donde se modifican los pesos de las capas ocultas; es por ello que tiene aplicación en modelos neuronales que posean 1 o más capas ocultas.

**Elipsoide.** Modelo fisicomatemático que representa a la Tierra, caracterizado por las constantes geométricas  $a$  (semieje mayor) y  $f$  (aplanamiento), y los parámetros físicos  $\omega$  (velocidad angular de rotación) y  $m$  (masa).

**Entrenamiento.** Se refiere a la adquisición de conocimiento, habilidades, y capacidades como resultado de la enseñanza (aprendizaje), durante esta fase se utilizan algoritmos de aprendizaje. Tiene como finalidad ajustar los parámetros de la red con el fin de que las entradas produzcan las salidas deseadas con el fin de minimizar la función error.

Función de activación

Son grados de activación que poseen los nodos o neuronas limitándose únicamente en dos: inactiva (0 ó -1) y activa (1)

**Geoide.** Superficie equipotencial del campo de gravedad que se aproxima al nivel medio del mar en calma.

**Neurona artificial.** Unidad simple de procesamiento que conforma una red neuronal, tienen la habilidad de aprender realizando sus propias reglas a través de la experiencia y también poseen la destreza de generalizar. Cada neurona recibe una serie de entradas a través de interconexiones y emite una salida.



**Neurona presináptica**

Célula nerviosa que transmite los impulsos nerviosos.

**Neurona postsináptica**

Célula nerviosa que recibe los impulsos nerviosos, ya sea a través de un neurotransmisor (sinapsis química) o por medio de uniones entre la membrana plasmática (sinapsis eléctrica).

**Ondulación geoidal (N)**

Diferencia de altura entre el geoide y el elipsoide.

**Patrón de entrada.** Son el conjunto de variables independientes de entrada que se han elegido para representar el sistema que se quiere modelar, consiste en los datos disponibles para el entrenamiento.

**Patrón de salida.** Es el conjunto de variables de respuesta del sistema a modelar, correspondiente a un patrón de entrada.

**Patrón de validación.** Conjunto de datos que mide la capacidad de la red para responder correctamente ante patrones que no han sido utilizados durante el entrenamiento. Estos datos se obtienen de la separación aleatoria de las muestras disponibles sobre el problema, siendo no utilizados como parte del patrón de entrada de la red.

**Pesos sinápticos.** Valores aleatorios que se presentan a la red durante el proceso de entrenamiento, la modificación de los mismos tiene el propósito de almacenar el conocimiento adquirido para alcanzar el objetivo o la solución de un problema dado, es aquí donde se produce el aprendizaje de la red.

**Razón de aprendizaje.** Es un parámetro encargado de controlar cuanto se desplazan los pesos de la red en la superficie del error siguiendo la dirección negativa del

gradiente, determinando por lo tanto la magnitud de dicho desplazamiento, influyendo así en la velocidad de convergencia del algoritmo.

**Red neuronal artificial (RNA).** Las redes neuronales artificiales son consideradas sistemas de procesamiento de información paralelos, distribuidos y adaptativos, los cuales pretenden construir modelos matemáticos que representen ciertas características y comportamiento de las redes neuronales biológicas, siendo simulados mediante programas de computador.

**Señal de error.** La señal de error está definida como la diferencia entre una respuesta deseada y la respuesta real de la red. Se propagan hacia atrás en forma de ajuste de los pesos sinápticos con la finalidad de alcanzar la meta deseada para un problema dado.

**Señal funcional.** Constituye una señal de entrada la cual se propaga hacia delante a través de la red hasta llegar como una señal de salida.

**Sinapsis.** Contacto, muy especializado, que se establece entre dos neuronas y a través del cual se transmiten las señales nerviosas de unas células nerviosas a otras. Existen dos clases de sinapsis: eléctricas y químicas.

**Umbral o límite.** Representa la mínima entrada total ponderada necesaria para provocar la activación de la neurona. También pueden definirse versiones límite de las funciones signo y sigmoides.

ANEXOS

ANEXO A



INSTITUTO GEOGRÁFICO NACIONAL  
DIRECCIÓN DE GEODESIA  
DESCRIPCIÓN MONOGRÁFICA




PROYECTO CONSOLIDACIÓN DE LOS DERECHOS DE LA PROPIEDAD INMUEBLE

CÓDIGO: PNO1		LOCALIDAD: PUNO		ESTABLECIDA POR: INSTITUTO GEOGRÁFICO NACIONAL	
UBICACIÓN: MIRADOR MUNICIPAL DE KUNTUR WASI			CARACTERÍSTICAS DE LA MARCA: DISCO DE BRONCE 5 cm. DIÁMETRO		
LATITUD ( S ) WGS-84 15°50'49.0392"			LONGITUD ( O ) WGS-84 70°1'48.3719"		
NORTE ( Y ) WGS-84 8217722.6715			ESTE ( X ) WGS-84 389699.0359		
ALTURA ELIPSOIDAL 4037.7440	ELEVACIÓN GEOIDAL 3992.1020	ZONA UTM 19 SUR	ORDEN B		
<p><u>CROQUIS</u></p>					
<p><b>LOCALIZACIÓN:</b>                  Distrito: Puno                  Provincia: Puno                  Departamento: Puno</p>					
<p><b>DESCRIPCIÓN:</b>                  La Estación "PNO1", se encuentra ubicada en el extremo norte del mirador de Kuntur Wasi.</p>					
<p><b>MARCA DE ESTACIÓN:</b>                  Es un disco de bronce de 5 cm. de diámetro, incrustado a ras del suelo y lleva grabado la siguiente inscripción: "PNO1 - PCDPI - 2008".</p>					
<p><b>REFERENCIA:</b>                  Carta Nacional Escala 1/100 000, Hoja 32-v Puno.</p>					
DESCRITA POR: Garma/Pachamango	REVISADO: Tte. Ing. J. Romero A.	JEFE PROYECTO: My. Ing. C. Sierra F.	FECHA: Agosto 2008		


ANEXOS

ANEXO B



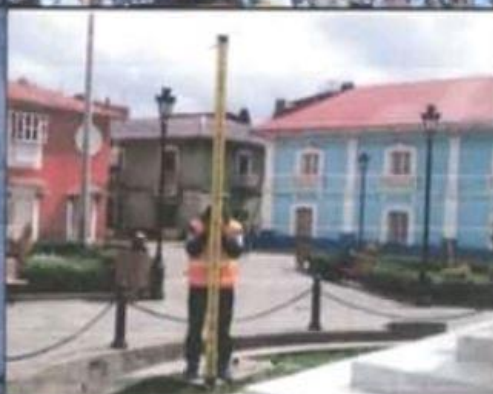


**INSTITUTO GEOGRÁFICO NACIONAL**  
**DIRECCIÓN DE GEODESIA**

DESCRIPCIÓN MONOGRÁFICA



<b>NOMBRE:</b> PFCV AUX-01 PUN		<b>ESTABLECIDA POR:</b> INSTITUTO GEOGRÁFICO NACIONAL	
<b>DATUM</b> Red de Nivelación Nacional (RNN) Sobre Nivel Medio del Mar (s.n.m.m.)		<b>DEPARTAMENTO:</b> PUNO	<b>PROVINCIA:</b> Puno
<b>LÍNEA DE NIVELACIÓN</b> Puno-Desaguadero-Matarani		<b>LOCALIDAD:</b> Puno	<b>LUGAR:</b> Parque Manuel Pino
<b>ALTURA NIVELADA (m)</b> 3828.4108		<b>REFERENCIA:</b> Carta Nacional 32-v 1: 100 000	

**DESCRIPCIÓN :**  
 El punto de fotocontrol vertical denominado PFCV AUX-01 PUN, está ubicado en el vértice suroeste del muro de un buzón, en Pino el Parque, en la localidad de Puno, con coordenadas aproximadas: E 389911 N 8248744, zona 19 Sur en el sistema WGS84.

<b>OPERADOR:</b> TCOJ EP O. Tito F.	<b>REVISADO POR :</b> TCO1 EP E. Alva L.	<b>ADJ. JEFE BRIGADA:</b> CAP EP J. Chire C.	<b>JEFE DE BRIGADA:</b> Tte Crí. EP E. Huarajo C.	<b>DIR. DE GEODESIA:</b> MY EP J. Saenz A.	<b>FECHA:</b> Enero 2017
--	---	---	--	---	-----------------------------