

UNIVERSIDAD NACIONAL DE SAN CRISTÓBAL DE  
HUAMANGA

FACULTAD DE INGENIERÍA DE MINAS, GEOLOGÍA Y  
CIVIL

ESCUELA DE FORMACIÓN PROFESIONAL DE  
INGENIERÍA CIVIL



TESIS PARA OPTAR EL TÍTULO DE INGENIERO CIVIL

«REDES NEURONALES ARTIFICIALES COMO HERRAMIENTA DE  
VALIDACIÓN DE LA PRECIPITACIÓN OBTENIDA MEDIANTE  
PERCEPCIÓN REMOTA»

PRESENTADO POR:  
MIGUEL RAÚL GUZMÁN PRADO

ASESOR:  
ING. EDMUNDO CANCHARI GUTIÉRREZ

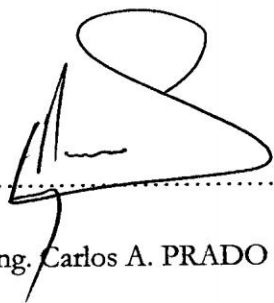
AYACUCHO - PERÚ

2014

**“REDES NEURONALES ARTIFICIALES COMO HERRAMIENTA  
DE VALIDACIÓN DE LA PRECIPITACIÓN OBTENIDA  
MEDIANTE PERCEPCIÓN REMOTA”**

RECOMENDADO: 29 de Octubre del 2014

APROBADO: 25 de Noviembre del 2014



M. Sc. Ing. Carlos A. PRADO PRADO

(Presidente)



Ing. Cristian CASTRO PÉREZ

(Miembro)



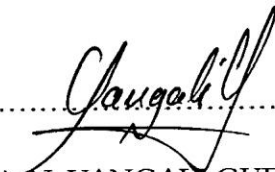
Ing. Edmundo CANCHARI GUTIÉRREZ

(Miembro)



Ing. Jaime L. BENDEZÚ PRADO

(Miembro)



Ing. Floro N. YANGALI GUERRA

(Secretario Docente)

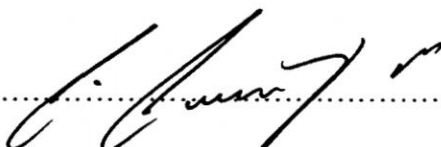
Según el acuerdo constatado en el Acta, levantada el 25 de Noviembre del 2014, en la Sustentación de Tesis Profesional, presentado por el Bachiller en Ciencias de la Ingeniería Civil señor Miguel Raúl Guzmán Prado, con el trabajo titulado **“REDES NEURONALES ARTIFICIALES COMO HERRAMIENTA DE VALIDACIÓN DE LA PRECIPITACIÓN OBTENIDA MEDIANTE PERCEPCIÓN REMOTA”**, fue calificado con la nota de QUINCE (15) por lo que se da la respectiva APROBACIÓN.



.....

M. Sc. Ing. Carlos A. PRADO PRADO

(Presidente)



.....

Ing. Cristian CASTRO PÉREZ

(Miembro)



.....

Ing. Edmundo CANCHARI GUTIÉRREZ

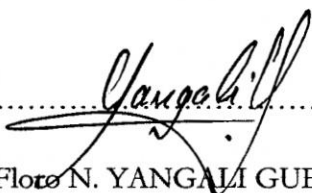
(Miembro)



.....

Ing. Jaime L. BENDEZÚ PRADO

(Miembro)



.....

Ing. Flore N. YANGALI GUERRA

(Secretario Docente)

# Presentación

La presente tesis lleva por título «Redes Neuronales Artificiales Como Herramienta de Validación de la Precipitación Obtenida Mediante Percepción Remota», como una contribución a la investigación en el área de la ingeniería hidráulica (Hidrología más específicamente).

La realización de esta investigación se debe a que en el territorio nacional, con frecuencia, se dispone de una carencia de información en los estudios de estimación del potencial hídrico para su aprovechamiento de una determinada cuenca hidrográfica; además de contar con una baja densidad de distribución de estaciones meteorológicas y la poca existencia de estaciones hidrológicas. La presente tesis tiene como objetivo principal diseñar un modelo metaheurístico basado en redes neuronales artificiales como herramienta de validación de la precipitación registrada por el radar TRMM en la cuenca del Río Cachi, utilizando MATLAB como una herramienta de diseño y procesamiento de datos.

Esperando que su fundamentación y aplicación sirva a todos aquellos profesionales y estudiantes inmersos en la adquisición de conocimientos y desarrollo de investigaciones.

MIGUEL RAÚL GUZMÁN PRADO

<http://miguelraul123456.wix.com/stran>

UNIVERSIDAD NACIONAL DE SAN CRISTÓBAL DE HUAMANGA

FACULTAD DE INGENIERÍA DE MINAS, GEOLOGÍA Y CIVIL

ESCUELA DE FORMACIÓN PROFESIONAL DE INGENIERÍA CIVIL

AYACUCHO, 1 DE DICIEMBRE DE 2014

# Dedicatoria

*A mi familia, quienes me apoyaron y seguirán apoyando de manera incondicional en mi formación académica y a todas aquellas personas que siguen los caminos necesarios para hacer realidad sus sueños.*

# Agradecimientos

- A la Universidad Nacional San Cristóbal de Huamanga, por la formación académica recibida en los años transcurridos durante mis estudios.
- A los alumnos, egresados y docentes de la Escuela de Formación Profesional de Ingeniería Civil, por los conocimientos y experiencias transmitidos que contribuyeron de manera determinante en mi formación profesional y perspectiva profesional.
- A MathWorks y su producto MATLAB por permitirnos desarrollar aplicaciones en Ingeniería Civil gracias a su entorno interactivo para el cálculo numérico, visualización y programación.
- Al SENAMHI por su ayuda en la recolección de datos.
- Un agradecimiento especial a mi familia. En especial a mis padres, Raúl Guzmán Aparco y Consuelo Prado Osorio, por brindarme su apoyo incondicional durante toda la vida.
- Y a todas aquellas personas que de una u otra manera, colaboraron o participaron en la realización de esta investigación, hago extensivo mi más sincero agradecimiento.

# Resumen

La realización de esta investigación se debió a que en el territorio nacional, con frecuencia, se dispone de una carencia de información en los estudios de estimación del potencial hídrico para su aprovechamiento de una determinada cuenca hidrográfica. La presente tesis tuvo como objetivo principal diseñar un modelo de Inteligencia Artificial basado en redes neuronales artificiales como herramienta de validación de la precipitación registrada por el radar TRMM en la Cuenca del Río Cachi, utilizando MATLAB como una herramienta de diseño y procesamiento de datos.

La Metodología empleada en este estudio es de tipo cuantitativa y consistió básicamente en las siguientes etapas:

- Delimitación de la Cuenca del Río Cachi a partir de las Cartas Geográficas proporcionadas por el IGN (Instituto Geográfico Nacional).
- Recolección de datos a partir del SENAMHI (Servicio Nacional de Meteorología e Hidrología) y el TRMM (Misión de la Medición de Lluvias Tropicales).
- Diseño y Establecimiento de la Red Neuronal empleando MATLAB.

Al establecer la Red Neuronal (parámetros e indicadores adecuados), este nos permitió la extensión a otros puntos de interés sobre la Cuenca del río Cachi. Las salidas de la Red Neuronal para estaciones involucradas en el presente estudio resultaron ser muy semejantes a las mediciones in situ. Mientras que las Salidas de la Red Neuronal a estaciones que no estuvieron involucradas en el presente estudio son aceptables; las mismas que se basan en el buen aprendizaje que tuvo la Red Neuronal y observaciones gráficas del comportamiento de las Series Temporales.

# Índice general

<b>Portada</b>	<b>I</b>
<b>Presentación</b>	<b>I</b>
<b>Dedicatoria</b>	<b>II</b>
<b>Agradecimientos</b>	<b>III</b>
<b>Resumen</b>	<b>IV</b>
<b>Índice general</b>	<b>V</b>
<b>Índice de figuras</b>	<b>XIII</b>
<b>Índice de cuadros</b>	<b>XVIII</b>
<b>I Introducción</b>	<b>1</b>
<b>1. Introducción</b>	<b>2</b>
1.1. Motivación de la investigación . . . . .	2
1.2. Planteamiento del problema . . . . .	4
1.2.1. Antecedentes . . . . .	4
1.2.2. Problema . . . . .	5
1.2.2.1. Problema Central . . . . .	5
1.2.2.2. Problema Específicos . . . . .	5
1.2.3. Objetivos . . . . .	6

1.2.3.1.	Objetivo General . . . . .	6
1.2.3.2.	Objetivo Específico . . . . .	6
1.2.4.	Hipótesis . . . . .	6
1.2.4.1.	Hipótesis General . . . . .	6
1.2.4.2.	Hipótesis Específica . . . . .	7
1.3.	Justificación . . . . .	7
1.4.	Metodología aplicada . . . . .	8
1.4.1.	Tipo de Investigación . . . . .	8
1.4.2.	Nivel de Investigación . . . . .	8
1.4.3.	Diseño de Investigación . . . . .	8

## **II Marco Teórico 9**

### **2. Principios Básicos de Teledetección 10**

2.1.	Introducción . . . . .	10
2.2.	Detalles Históricos . . . . .	11
2.3.	Elementos del Proceso de Teledetección . . . . .	14
2.4.	El Espectro Electromagnético . . . . .	15
2.5.	Reflectancia de las superficies terrestres . . . . .	16
2.6.	Caraterísticas orbitales de los satélites de teledetección . . . . .	18
2.7.	Resolución de los sensores remotos . . . . .	20
2.7.1.	Resolución espacial . . . . .	20
2.7.2.	Resolución espectral . . . . .	21
2.7.3.	Resolución radiométrica . . . . .	21
2.7.4.	Resolución temporal . . . . .	22
2.8.	Tipos de imágenes de teledetección . . . . .	23
2.8.1.	Imagen multiespectral (MS). . . . .	23
2.8.2.	Imagen pancromática (PAN). . . . .	23
2.8.3.	Imagen fusionada (PS). . . . .	24
2.8.4.	Imagen estéreo. . . . .	24



4.2.1.1.	Propagación de los patrones de entrada . . . . .	51
4.2.1.2.	Diseño de la arquitectura del perceptron multicapa . . . . .	54
4.2.2.	Algoritmo de RetroPropagación . . . . .	55
4.2.2.1.	Obtención de la regla delta generalizada . . . . .	57
4.2.2.2.	Razón de aprendizaje. Inclusión del momento en la ley de aprendizaje. . . . .	62
4.2.3.	Proceso de aprendizaje del Perceptron multicapa. . . . .	64
4.2.3.1.	Capacidad de generalización. . . . .	66
4.2.3.2.	Deficiencias del algoritmo de aprendizaje. . . . .	66
<b>III</b>	<b> Materiales y Métodos</b>	<b>68</b>
<b>5.</b>	<b>Medición de la Precipitación global</b>	<b>69</b>
5.1.	Misión de la Medición de las Lluvias Tropicales TRMM . . . . .	69
5.1.1.	Descripción General de la Misión TRMM . . . . .	70
5.1.2.	Instrumentos del TRMM . . . . .	72
5.1.2.1.	Escáner Visible e Infrarrojo (VIRS) . . . . .	73
5.1.2.2.	TRMM Microondas Generador de Imagen (TMI) . . . . .	74
5.1.2.3.	El Radar de Precipitación (PR) . . . . .	74
5.1.2.4.	Las Nubes y el Sistema de Energía Radiante de la Tierra (CERES) . . . . .	75
5.1.2.5.	Sensor de Imágenes de Rayos (LIS) . . . . .	75
5.1.3.	Características de la órbita del TRMM . . . . .	77
5.1.4.	La geometría de escaneo del Radar de precipitación PR del TRMM . . . . .	77
5.1.5.	Descripción general los productos del TRMM . . . . .	79
<b>6.</b>	<b>Redes de Neuronas Artificiales (Enfoque MATLAB)</b>	<b>80</b>
6.1.	Introducción a la Caja de Herramientas de Redes Neuronales de MATLAB . . . . .	80
6.1.1.	Flujo de Trabajo para Diseño de Redes Neuronales . . . . .	80

6.1.2.	Cuatro Niveles de Diseño de Redes Neuronales . . . . .	81
6.1.3.	Modelo de Neurona . . . . .	82
6.1.3.1.	Neurona Simple . . . . .	82
6.1.3.2.	Funciones de Transferencia . . . . .	83
6.1.3.3.	Neurona con vector de ingreso . . . . .	84
6.1.3.4.	Notación abreviada . . . . .	84
6.1.4.	Arquitecturas de la Red Neuronal . . . . .	85
6.1.4.1.	Una Capa de Neuronas . . . . .	85
6.1.4.2.	Ingresos y Capas . . . . .	87
6.1.4.3.	Múltiples Capas de Neuronas . . . . .	88
6.1.4.4.	Funciones de procesamiento de ingresos y salidas . . . . .	90
6.1.4.5.	Crear Objeto Red Neuronal . . . . .	90
6.2.	Redes Neuronales de Múltiples Capas y Entrenamiento de Retropropagación . . . . .	90
6.2.1.	Arquitectura de la Red Neuronal de Múltiples Capas . . . . .	91
6.2.1.1.	Neurona modelo (logsig, tansig, purelin) . . . . .	91
6.2.1.2.	Red neuronal feedforward . . . . .	92
6.2.2.	Preparar datos para redes de múltiples capas . . . . .	93
6.2.3.	Elegir funciones de procesamiento de ingresos y salidas de la red neuronal . . . . .	94
6.2.4.	Representando objetivos desconocidos . . . . .	96
6.2.5.	Dividir datos para el entrenamiento óptimo de la Red Neuronal . . . . .	96
6.2.6.	Crear, Configurar e inicializar Redes Neuronales de Múltiples Capas . . . . .	97
6.2.7.	Otras arquitecturas relacionadas . . . . .	97
6.2.8.	Inicializando pesos (init) . . . . .	98
6.2.9.	Entrenar y aplicar Redes de Neuronas de Múltiples Capas . . . . .	98
6.2.10.	Algoritmos de entrenamiento . . . . .	99
6.2.11.	Uso de la red . . . . .	101

6.2.12. Analizar en rendimiento de la red neuronal después del entrenamiento . . . . .	101
6.2.13. Mejorar los resultados . . . . .	102
6.2.14. Limitaciones y precauciones . . . . .	102
6.3. Ajustando una función . . . . .	103
6.3.1. Inicio de Red Neuronal (nnstart) . . . . .	103
6.3.2. Herramienta de ajuste de Red Neuronal (nftool) . . . . .	103
<b>7. Validación de la precipitación derivada del TRMM sobre la Cuenca del Río Cachi</b>	<b>109</b>
7.1. Introducción . . . . .	110
7.2. Área de estudio . . . . .	110
7.2.1. Ubicación y Localización . . . . .	110
7.3. Datos y Metodología . . . . .	111
7.3.1. Datos utilizados . . . . .	111
7.3.1.1. Delimitación de la Cuenca del Río Cachi . . . . .	111
7.3.1.2. Datos del algoritmo 3B43 V7 del TRMM . . . . .	112
7.3.1.3. Datos del SENAMHI . . . . .	114
7.3.1.4. Comparación Gráfica de Series Temporales del algoritmo 3B43 V7 del TRMM y SENAMHI . . . . .	116
7.3.2. Procedimiento de diseño y análisis . . . . .	118
7.3.2.1. Matriz de Ingreso y Matriz Objetivo de la Red Neuronal . . . . .	118
7.3.2.2. Procedimiento de acuerdo a MATLAB . . . . .	124
<b>IV Resultados</b>	<b>132</b>
<b>8. Resultados y Discusiones</b>	<b>133</b>
8.1. Distribución de precipitaciones mensuales sobre la Cuenca del Río Cachi como se observa a partir del TRMM . . . . .	133

8.2. Distribución de precipitaciones estacionales sobre la Cuenca del Río Cachi como se observa a partir del TRMM . . . . .	135
8.3. Distribución de precipitaciones anuales sobre la Cuenca del Río Cachi como se observa a partir del TRMM . . . . .	136
8.4. Comparación de precipitación día a día . . . . .	137
8.5. Comparación de precipitación mes a mes . . . . .	138
8.6. Salida de la Red Neuronal a otras estaciones . . . . .	138
<b>V Conclusiones</b>	<b>147</b>
<b>9. Conclusiones, Recomendaciones e Investigaciones Futuras</b>	<b>148</b>
9.1. Conclusiones . . . . .	148
9.1.1. De la teoría . . . . .	148
9.1.2. De la metodología . . . . .	149
9.1.3. Del modelo de Red Neuronal utilizado . . . . .	150
9.1.4. De los resultados . . . . .	155
9.1.5. De la tesis . . . . .	156
9.2. Recomendaciones . . . . .	157
9.3. Investigaciones futuras . . . . .	157
<b>Referencias</b>	<b>159</b>
<b>VI Anexos</b>	<b>162</b>
<b>A. Análisis de Registros Anuales</b>	<b>163</b>
A.1. Análisis de Homogeneidad o Consistencia . . . . .	163
A.1.1. Concepto de homogeneidad de la serie . . . . .	163
A.1.2. Tipos de Pruebas Estadísticas de Homogeneidad . . . . .	163
A.1.3. Prueba Estadística de la t de Student . . . . .	164
<b>B. Guía de Usuario del Programa PERC</b>	<b>168</b>

B.1. Ventana Principal . . . . .	168
B.2. Adquisición de datos del TRMM . . . . .	170
B.3. Establecimiento de datos para presentación de Series Temporales . . .	172
B.4. Diagrama de flujo del programa PERC . . . . .	173
B.5. Resultados . . . . .	175
<b>C. M-Files utilizados en el estudio de Validación</b>	<b>177</b>
C.1. Código de la función para la rotación de las abcisas en las Gráficas de Series Temporales. . . . .	177
C.2. Script para resolver un problema de ajuste usando el NFTOOL de MATLAB. . . . .	179
C.3. M-File relacionado al programa PERC (Programa de extensión de precipitaciones mensuales sobre la Cuenca del Río Cachi). . . . .	181
<b>D. Fotografías</b>	<b>185</b>
<b>E. Planos</b>	<b>188</b>

# Índice de figuras

2.1. Imagen de la Tierra resultado de la combinación de diferentes sensores de teledetección. . . . .	11
2.2. Cohete V-2 y una de las primeras fotografías tomadas desde estos cohetes. . . . .	12
2.3. TIROS-I y primera imagen de televisión desde el espacio. . . . .	12
2.4. LANDSAT 7 antes de su puesta en órbita. . . . .	13
2.5. Elementos de un Proceso de Teledetección desde Satélites. . . . .	14
2.6. Espectro Electromagnético. . . . .	15
2.7. Curvas de Reflectancia Espectral. . . . .	17
2.8. Órbita de los satélites de Teledetección. . . . .	18
2.9. Ancho de barrido. . . . .	19
2.10. Formato de una imagen digital (7 x 9 píxeles). . . . .	20
2.11. Mayor resolución temporal gracias a la reorientación de sensores en pases consecutivos. . . . .	22
3.1. Precipitación en estado líquido y en forma de un chubasco. . . . .	26
3.2. El Ciclo del Agua. . . . .	27
3.3. Pluviómetro. . . . .	29
3.4. Pluviógrafo. . . . .	30
3.5. Estación automática de precipitación. . . . .	30
3.6. El Radar NPOL de la NASA. . . . .	31
3.7. Micro Radar de precipitación. . . . .	31
3.8. El Radar Doppler de la NASA. . . . .	32

4.1. Descripción de una célula nerviosa típica. . . . .	40
4.2. Esquema de una unidad de proceso típica. . . . .	43
4.3. Esquema de una red de tres capas totalmente interconectadas. . . . .	44
4.4. Aprendizaje supervisado. . . . .	46
4.5. Aprendizaje no supervisado. . . . .	46
4.6. Arquitectura del PERCEPTRON multicapa. . . . .	50
4.7. Funciones de activación del PERCEPTRON multicapa. . . . .	53
5.1. El Satélite TRMM. . . . .	70
5.2. Instrumentos del TRMM. . . . .	72
5.3. Escáner Visible e Infrarrojo (VIRS). . . . .	73
5.4. Las Nubes y el Sistema de Energía Radiante de la Tierra (CERES). . . . .	76
5.5. Geometría de escaneo actual del radar de precipitación a bordo del satélite TRMM. . . . .	78
6.1. Neurona de entrada única. . . . .	82
6.2. Funciones de Transferencia. . . . .	83
6.3. Neurona de entrada única con vector de ingreso. . . . .	84
6.4. Notación abreviada de neurona de entrada única. . . . .	85
6.5. Red de una sola capa con R elementos de ingreso y S neuronas. . . . .	86
6.6. Notación abreviada de una red de una sola capa con R elementos de ingreso y S neuronas. . . . .	87
6.7. Red de ingreso múltiple de una sola capa. . . . .	88
6.8. Red de ingreso múltiple de tres capas. . . . .	89
6.9. Notación abreviada de red de ingreso múltiple de tres capas. . . . .	89
6.10. Red de ingreso múltiple de una sola capa. . . . .	91
6.11. Funciones de Transferencia. . . . .	92
6.12. Red de ingreso múltiple de una sola capa en notación abreviada. . . . .	93
6.13. Red de ingreso múltiple de dos capas en notación abreviada. . . . .	93
6.14. Bloques de pre-procesamiento y post-procesamiento. . . . .	95
6.15. Inicio de la Caja de Herramientas de Redes Neuronales. . . . .	103

6.16. Ventana de la Herramienta de ajuste de Red Neuronal. . . . .	104
6.17. Ventana de selección de ingresos y objetivos. . . . .	105
6.18. Ventana de datos de validación y prueba. Fuente: Fuente: Matlab 2014a.	105
6.19. Ventana de arquitectura de la Red Neuronal. . . . .	106
6.20. Ventana de entrenamiento de la Red Neuronal. . . . .	107
6.21. Ventana interactiva del progreso del entrenamiento de la Red Neuronal.	108
7.1. El Satélite TRMM. . . . .	109
7.2. Cuenca del Río Cachi y Ubicación de las Estaciones Pluviométricas. .	112
7.3. Estación Huanta (TRMM y SENAMHI). . . . .	116
7.4. Estación La Quinoa (TRMM y SENAMHI). . . . .	116
7.5. Estación San Pedro de Cachi (TRMM y SENAMHI). . . . .	117
7.6. Estaciones Pluviométricas (SENAMHI). . . . .	117
7.7. Estaciones Sintéticas (TRMM). . . . .	117
7.8. Ventana de inicio de Red Neuronal. . . . .	124
7.9. Ventana de Red Neuronal para ajuste. . . . .	125
7.10. Ventana de selección de ingresos y objetivos de Red Neuronal. . . . .	126
7.11. Ventana de división de datos de ingreso de Red Neuronal. . . . .	127
7.12. Arquitectura de la Red Neuronal. . . . .	127
7.13. Ventana de entrenamiento de la Red Neuronal. . . . .	128
7.14. Ventana de supervisión del progreso del entrenamiento de Red Neuronal. . . . .	129
7.15. Ventana de errores de entrenamiento, validación y prueba de Red Neuronal. . . . .	129
7.16. Ventana de regresión lineal de la Red Neuronal. . . . .	131
8.1. Distribución espacial de precipitaciones mensuales sobre la Cuenca del Río Cachi. . . . .	134
8.2. Distribución espacial de precipitaciones estacionales sobre la Cuenca del Río Cachi. . . . .	135
8.3. Distribución espacial de precipitaciones anuales sobre la Cuenca del Río Cachi. . . . .	136

8.4. Ventana principal del programa PERC. . . . .	139
8.5. Ubicación de estaciones no involucradas en este estudio sobre la Cuenca del Río Cachi. . . . .	140
8.6. Precipitación diaria de la Estación Alpachaca (2004). . . . .	142
8.7. Precipitación diaria de la Estación Alpachaca (2007). . . . .	142
8.8. Precipitación diaria de la Estación La Quinoa (2009). . . . .	142
8.9. Precipitación diaria de la Estación La Quinoa (2012). . . . .	143
8.10. Precipitación diaria de la Estación Wayllapampa (2009). . . . .	143
8.11. Precipitación diaria de la Estación Wayllapampa (2012). . . . .	143
8.12. Precipitación diaria de la Estación Huanta (2009). . . . .	144
8.13. Precipitación diaria de la Estación San Pedro de Cachi (2012). . . . .	144
8.14. Precipitación diaria de la Estación Huamanga(2008). . . . .	144
8.15. Precipitaciones mensuales de la estación Huanta. . . . .	145
8.16. Precipitaciones mensuales de la estación La Quinoa. . . . .	145
8.17. Precipitaciones mensuales de la estación San Pedro de Cachi. . . . .	145
8.18. Salida de la Red Neuronal para la Estación A. . . . .	146
8.19. Salida de la Red Neuronal para la Estación B. . . . .	146
8.20. Salida de la Red Neuronal para la Estación C. . . . .	146
9.1. Red Neuronal establecida en el presente estudio con 120 neuronas en la Capa Oculta y 1 en la capa de Salida. . . . .	151
B.1. Ventana principal del programa PERC. . . . .	168
B.2. Descripción de las componentes del programa PERC. . . . .	169
B.3. Punto A sobre la Cuenca del Río Cachi. . . . .	170
B.4. Archivo de precipitaciones del Algoritmo 3B43 del TRMM. . . . .	171
B.5. Gráfico de precipitaciones del Algoritmo 3B43 del TRMM. . . . .	171
B.6. Valores de precipitaciones del Algoritmo 3B43 del TRMM. . . . .	172
B.7. Valores de precipitaciones del TRMM copiados en un bloc de notas. . . . .	173
B.8. Establecimiento de datos temporales en el programa PERC. . . . .	173
B.9. Diagrama de flujo del programa PERC. . . . .	174

B.10. Precipitaciones mensuales tabuladas (Salida de la Red). . . . .	175
B.11. Serie Temporal de precipitaciones mensuales (Salida de la Red). . . .	175
B.12. Precipitaciones mensuales tabuladas (TRMM). . . . .	176
B.13. Serie Temporal de precipitaciones mensuales (TRMM). . . . .	176
B.14. Serie Temporal de precipitaciones mensuales (Salida de la Red y TRMM). . . . .	176
D.1. Presa Cuchoquesera (Estructura Mayor de la Irrigación Cachi). . . . .	185
D.2. Sifón Invertido de la Irrigación Cachi. . . . .	186
D.3. Área Geográfica de la Irrigación Cachi. . . . .	186
D.4. Bocatoma de la Irrigación Cachi. . . . .	187
D.5. Válvulas de control de la Irrigación Cachi. . . . .	187

# Índice de cuadros

6.1. Funciones de pre-procesamiento y post-procesamiento más comunes. . . . .	95
6.2. Funciones para dividir datos. . . . .	97
6.3. Algoritmos de entrenamiento. . . . .	100
7.1. Estaciones Sintéticas de la Medición de la Precipitación Global. . . . .	113
7.2. Precipitación mensual de la Estaciones Sintéticas (TRMM). . . . .	114
7.3. Estaciones Pluviométricas del SENAMHI. . . . .	115
7.4. Precipitación mensual de la Estaciones Pluviométricas (SENAMHI). . . . .	115
7.5. Matriz de Ingreso y Objetivo de la Red. . . . .	118
7.6. Funciones para dividir datos. . . . .	125
8.1. Series, Nombres y Coordenadas Geográficas de las estaciones no involucradas en este estudio. . . . .	141
9.1. Pesos y Umbrales de la Red Neuronal. . . . .	152
A.1. Prueba Estadística de la t de Student (Estación Huanta - SENAMHI). . . . .	164
A.2. Prueba Estadística de la t de Student (Estación Huanta - Salida de la Red Neuronal). . . . .	165
A.3. Prueba Estadística de la t de Student (Estación La Quinoa - SENAMHI). . . . .	165
A.4. Prueba Estadística de la t de Student (Estación La Quinoa - Salida de la Red Neuronal). . . . .	166
A.5. Prueba Estadística de la t de Student (Estación San Pedro de Cachi - SENAMHI). . . . .	166

A.6. Prueba Estadística de la t de Student (Estación San Pedro de Cachi	
- Salida de la Red Neuronal). . . . .	167

# Parte I

## Introducción

# Capítulo 1

## Introducción

### 1.1. Motivación de la investigación

En el territorio nacional, con frecuencia, se dispone de una carencia de información en los estudios de estimación del potencial hídrico para su aprovechamiento de una determinada cuenca hidrográfica, además de contar con una baja densidad de la distribución de las estaciones meteorológicas en el territorio nacional y la poca existencia de las estaciones hidrológicas. El registro de las precipitaciones a nivel diario son datos fundamentales cuando no se dispone del registro de caudales en el punto de interés (que generalmente se corresponde como el punto elegido desde el cual se aprovechará el recurso hídrico) para seguidamente, mediante los modelos heurísticos de precipitación y escorrentía es posible estimar los hidrogramas, que representan el potencial hídrico de una determinada cuenca hidrográfica.

Dado la existencia de estos inconvenientes se aprovechará el registro de las precipitaciones obtenidos mediante la red de satélites del Proyecto «Misión de Medición de la Precipitación» (PMM: Precipitations Measurement Mission<sup>1</sup>), que une en un solo proyecto las misiones TRMM (Tropical Rainfall Measuring Mission<sup>2</sup>) y GPM (Global Precipitation Measurement<sup>3</sup>). La red de satélites TRMM (Tropical Rainfall Measuring Mission - Misión de Medición de Lluvias tropicales); el satélite TRMM

---

<sup>1</sup>Página web oficial <http://pmm.nasa.gov/>

<sup>2</sup>Página web oficial <http://pmm.nasa.gov/TRMM>

<sup>3</sup>Página web oficial <http://pmm.nasa.gov/GPM>

fue lanzado el 27 de noviembre de 1997 entre la NASA (National Aeronautics and Space Administration - Administración Nacional de Aeronáutica y del Espacio) de los Estados Unidos de América y la Agencia JAXA (Japan Aerospace Exploration Agency - Agencia de Exploración Aeroespacial Japonesa) con la finalidad de monitorear y estudiar precipitaciones tropicales y subtropicales, entre las latitudes 35° Norte y 35° Sur; mientras que el proyecto GPM (Global Precipitation Measurement - Medición de Precipitaciones Globales) es una extensión del TRMM para medir las precipitaciones extendidamente en toda la tierra y será lanzado al espacio el 27 de febrero de 2014.

Las temáticas necesarias (lagos, red hídrica, topografía, ciudades, caminos, áreas protegidas, etc) en formato vectorial se obtienen desde el Instituto Geográfico Nacional (IGN) para el área de estudio, siguiendo con la caracterización morfo-métrica de la cuenca y el registro de las estaciones Hidro-Meteorológicas establecidas en la cuenca de estudio y cuencas vecinas. Para el registro de las estaciones hidrometeorológicas se tiene en cuenta el «*Mapa de Ubicación de las Estaciones Climatológicas*» y el «*Mapa de Ubicación de las Estaciones Hidrométricas*» obtenidas desde la ANA (Autoridad Nacional del Agua) y SENAMHI (Servicio Nacional de Meteorología e Hidrología), identificado el registro histórico de datos de precipitación, se realiza la comprobación de la consistencia y homogeneidad para luego extender a un mismo periodo de registro, seguidamente se obtiene la precipitación promedio en la zona de interés.

Por otra parte, se obtendrá las precipitaciones a partir del registro del proyecto GPM para la zona de interés, las mismas que serán sometidas a un análisis comparativo con las precipitaciones obtenidas por medidas directas, obtenidas desde SENAMHI y/o ANA. Las precipitaciones obtenidas en las estaciones climatológicas y las registradas por percepción remota no son los mismos y se acepta que las precipitaciones obtenidas en las estaciones climatológicas son las reales, por esta razón en el proceso de validación se obtendrá un modelo metaheurístico basado en Redes Neuronales Artificiales con la finalidad de obtener las precipitaciones a nivel de las estaciones climatológicas a partir de los registros de los satélites. La zona de estudio

estará delimitado por la cuenca del río Cachi y el proceso del diseño del modelo metaheurístico final se realizará desde MATLAB.

## **1.2. Planteamiento del problema**

En todo proyecto cuya finalidad es el Aprovechamiento de Recursos Hídricos de una determinada zona (una determinada cuenca hidrográfica) es necesario contar con el registro de variables hidrológicas y climatológicas; la información de la variable hidrológica se requiere en el punto de interés donde se fundará una estructura ya sea para el aprovechamiento del recurso hídrico o en protección contra éste, por otra parte, los registros climatológicos (temperatura, humedad, precipitación, etc.) generalmente son registrados en el área de influencia al punto de aprovechamiento del recurso hídrico (cuenca hidrográfica). En nuestro país las instituciones encargadas del registro y el mantenimiento de las estaciones hidro-meteorológicas son la «Autoridad Nacional del Agua» y el «Servicio Nacional de Meteorología e Hidrología» las mismas que se encuentran en proceso de desarrollo llevando proyectos de establecimiento de estaciones climáticas e hidrológicas en todo el Perú; pero las estaciones existentes actualmente son escasas, con muy poco registro histórico de información y una gran parte de las existentes no se encuentra en funcionamiento adecuado.

### **1.2.1. Antecedentes**

En el Perú existen investigaciones realizadas para el aprovechamiento del registro histórico de las precipitaciones del conjunto de los satélites del proyecto TRMM, en la Investigación «Análisis espacio temporal de la precipitación en las zonas de montaña de Perú (1998-2007)» publicado en la «Revista Peruana Geo-Atmosférica» en el año 2010, el estudio fue con el objetivo de estimar el comportamiento espacial y temporal de la precipitación sobre las zonas de montaña de los andes peruanos, se analizaron los registros mensuales de precipitación in situ (medidas en estaciones meteorológicas) y del satélite TRMM, específicamente el producto 3B43. A nivel de América del sur, el artículo titulado «¿Es el radar TRMM(NASA, JAXA) un

buen estimador de las precipitaciones de la región central Argentina?», publicado por la Universidad Nacional de San Luis - Argentina, el objetivo de este trabajo fue comparar los datos estimados por TRMM con los datos de campo registrados por pluviómetros del Servicio Meteorológico Nacional (Argentina), a lo largo de un gradiente de precipitaciones y a distintas escalas temporales; los resultados obtenidos fueron buenos en estimar tendencias globales y patrones regionales de distribución espacial, pero no con suficiente resolución a escalas de más detalle. A nivel de América del Norte y Europa existe muchos estudios con la misma finalidad que los estudios locales - que es validar las precipitaciones registradas por TRMM para aprovecharlo en estudios de la estimación del potencial hídrico de una cuenca.

## **1.2.2. Problema**

### **1.2.2.1. Problema Central**

¿Es posible diseñar un modelo de Inteligencia Artificial basado en redes neuronales artificiales como herramienta de validación de la precipitación registrada por el radar TRMM para la cuenca del río Cachi?

### **1.2.2.2. Problema Específicos**

- Carencia registro histórico de variables climáticas para realizar estudios en el planeamiento de proyectos que atañen el aprovechamiento de recursos hídricos.
- ¿Son las precipitaciones obtenidas mediante el satélite TRMM equivalentes a las obtenidas mediante mediciones directas por las estaciones meteorológicas en la cuenca del Río cachi?
- Necesidad de disponer con registros históricos de precipitaciones para extender los datos de las estaciones meteorológicas de la cuenca del Río Cachi.
- Insuficiencia de estaciones meteorológicas en la cuenca del Río Cachi.

### **1.2.3. Objetivos**

#### **1.2.3.1. Objetivo General**

Diseñar un modelo metaheurístico basado en redes neuronales artificiales como herramienta de validación de la precipitación registrada por el radar TRMM en la cuenca del Río Cachi.

#### **1.2.3.2. Objetivo Específico**

- Demostrar que los registros climatológicos obtenidos mediante la Red Neuronal a partir de datos del satélite TRMM son adecuados para el planeamiento de proyectos de aprovechamientos hídricos.
- Evaluar el análisis comparativo de las precipitaciones obtenidas mediante el satélite TRMM, las obtenidas mediante mediciones directas por las estaciones meteorológicas en la Cuenca del Río cachi y las obtenidas a partir de la Salida de la Red Neuronal.
- Demostrar que la Red Neuronal establecida, permitirá la extensión del registro histórico de las estaciones meteorológicas a partir de datos del TRMMM en la Cuenca del Río Cachi.
- Utilizar como herramienta de diseño de Red Neuronal y análisis de datos de precipitaciones el software MATLAB, debido a su gran potencial en cuanto a la visualización gráfica y análisis numérico.

### **1.2.4. Hipótesis**

#### **1.2.4.1. Hipótesis General**

Un modelo de Inteligencia Artificial basado en redes neuronales artificiales permitirá obtener (validar), desde las precipitaciones registradas por el radar TRMM, las precipitaciones equivalentes registradas en las estaciones meteorológicas de la cuenca del Río Cachi.

#### **1.2.4.2. Hipótesis Específica**

- Los registros climatológicos obtenidos mediante la Red Neuronal a partir de datos del satélite TRMM son adecuados para el planeamiento de proyectos de aprovechamientos hídricos.
- Las precipitaciones obtenidas mediante el satélite TRMM, las obtenidas mediante mediciones directas por las estaciones meteorológicas en la Cuenca del Río cachi y las obtenidas a partir de la Salida de la Red Neuronal son equivalentes.
- La Red Neuronal establecida, permitirá la extensión del registro histórico de las estaciones meteorológicas a partir de datos del TRMMM en la Cuenca del Río Cachi.
- MATLAB es adecuado como herramienta de diseño de Red Neuronal y análisis de datos de precipitaciones.

### **1.3. Justificación**

El Gobierno del Perú en los últimos años se encuentra impulsando el desarrollo en todas las áreas, entre ellos el aprovechamiento adecuado y sostenible de los recursos hídricos, con proyectos de diversa naturaleza: centrales hidroeléctricas, irrigaciones, dotación de agua para consumo humano, etc.; es en este punto el interés de disponer del registro histórico de los datos hidro-meteorológicos con la finalidad de estimar el recurso hídrico, dado la escasa información disponible por las instituciones encargadas (ANA, SENAMHI), no es posible el estudio adecuado del potencial hídrico en la zona de interés; es donde interviene el uso de los datos medidos con el satélite TRMM, que se encuentra como información libre con registros desde el año 1997.

## 1.4. Metodología aplicada

### 1.4.1. Tipo de Investigación

La investigación es del tipo **cuantitativa**, de tipo aplicativo tecnológico; se inicia con la delimitación y obtención de las características morfométricas de la cuenca en estudio, delimitado el área de interés es necesario identificar las estaciones meteorológicas y el registro de las precipitaciones, seguidamente se obtiene la información obtenida del registro de precipitaciones mediante el satélite TRMM para los puntos especificados de las estaciones meteorológicas; tomando como datos las precipitaciones obtenidas desde TRMM se obtendrá un modelo de Inteligencia Artificial cuyo resultado será las precipitaciones obtenidas en las estaciones meteorológicas, el modelo se utilizará para extender las precipitaciones a otros puntos en el área de interés.

### 1.4.2. Nivel de Investigación

El tipo de Diseño de Investigación del presente estudio es **Descriptiva** debido a la siguiente consideración:

- La presente investigación trata de caracterizar el comportamiento de las precipitaciones mensuales a través del tiempo en puntos sobre la Cuenca del Río Cachi.

### 1.4.3. Diseño de Investigación

El tipo de Diseño de Investigación del presente estudio es **Longitudinal** debido a las siguientes consideraciones:

- El interés es analizar cambios a través del tiempo de las precipitaciones mensuales sobre la Cuenca del Río Cachi.
- Recolección de datos a través del tiempo en puntos o periodos especificados para hacer inferencias respecto al cambio, determinantes y consecuencias.

## **Parte II**

### **Marco Teórico**

## Capítulo 2

# Principios Básicos de Teledetección


### 2.1. Introducción

La Tierra, como una esfera azulada en medio del Espacio (ver figura 2.1), sólo ha sido observada apenas por una veintena de privilegiados: los astronautas que viajaron a la Luna. Fueron los tripulantes de la nave espacial Apolo 8, a finales del año 1968, los primeros en disfrutar de ese espectáculo. Afortunadamente, en la actualidad, todos podemos tener esa visión de la Tierra desde el espacio gracias a los satélites de teledetección.

Pero ¿qué se entiende por teledetección? Teledetección es el vocablo usado por los hispanoparlantes para referirse al término inglés «remote sensing», que se traduce literalmente como percepción remota. Se refiere a la ciencia, técnica o incluso «arte» para algunos, de obtener información (imágenes) de la superficie de nuestro planeta a distancia, sin entrar en contacto directo con él. Pero la teledetección también incluye todo el trabajo realizado a posteriori con esas imágenes, es decir, su procesamiento e interpretación (Referencia [16]).

La teledetección más utilizada se refiere a la captura de imágenes desde satélites o plataformas aéreas (aviones, helicópteros o vehículos aéreos no tripulados). Sin embargo, las ventajas que ofrece la observación espacial desde satélites, esto es, la cobertura global y exhaustiva de la superficie terrestre, la observación multiescala y no destructiva y la cobertura repetitiva, han propiciado el desarrollo y utilización

**Figura 2.1:** Imagen de la Tierra resultado de la combinación de diferentes sensores de teledetección.



**Fuente:** Referencia [8].


de este tipo de productos de manera sistemática (Referencia [1]).

## 2.2. Detalles Históricos

La teledetección, tal y como se entiende en la actualidad, comenzó en el periodo de 1946 a 1950, cuando se lanzaron desde Nuevo México (EE.UU.) los primeros cohetes V-2 con pequeñas cámaras fotográficas instaladas en ellos como sensores remotos (ver figura 2.2). A partir de ese instante se sucedieron diferentes proyectos y misiones a bordo de otros cohetes, misiles balísticos y satélites, que realizaron la toma de fotografías de la Tierra. Aunque la calidad de las primeras fotografías desde el espacio no era muy buena, permitió revelar el verdadero potencial que le esperaba a esta técnica.

La observación sistemática de la Tierra comenzó en el año 1960 con el lanzamiento del TIROS-I (Television Infrared Observation Satellite-I) (ver figura 2.3), primer satélite meteorológico con una cámara de televisión de baja resolución espacial, que permitía a los meteorólogos discriminar entre nubes, agua, hielo y nieve. La serie de satélites TIROS, conocidos desde 1970 como NOAA (National Oceanic and Atmospheric Administration), continúa vigente en nuestros días, siendo el satélite NOAA-19 el último en haber sido puesto en órbita (información referida a febrero

**Figura 2.2:** Cohete V-2 y una de las primeras fotografías tomadas desde estos cohetes.



(a) Cohete V-2

(b) Fotografía

**Fuente:** Referencia [8].

de 2012) (Referencia [16]).

**Figura 2.3:** TIROS-I y primera imagen de televisión desde el espacio.



(a) TIROS-1

(b) Imagen de Televisión

**Fuente:** Referencia [8].

El excitante futuro que le esperaba a la teledetección se hizo definitivamente patente con los primeros programas espaciales tripulados en la década de los 60: Mercury, Gemini y Apollo. En las órbitas descritas por el Apollo 9 alrededor de la Tierra, antes de alunizar, se llevó a cabo el primer experimento controlado de fotografía multispectral para estudiar los recursos naturales de la superficie terrestre. Las fotografías se captaron usando una película pancromática con filtros rojos y verdes, otra película en blanco y negro del infrarrojo próximo y una última en color. Los

**Figura 2.4:** LANDSAT 7 antes de su puesta en órbita.



**Fuente:** Referencia [8].

buenos resultados obtenidos, junto a las imágenes de los primeros satélites meteorológicos, condujeron a la NASA (National Aeronautics and Space Administration) y al Departamento de Interior de los Estados Unidos, en 1967, a desarrollar el Programa de Observación ERTS (Earth Resources Technology Satellites), conocido con el nombre de LANDSAT (Referencia [1]). El primer satélite de esta serie se lanzó el 23 de julio de 1972 y operó hasta el 6 de enero de 1978. Este proyecto ha resultado ser uno de los más fructíferos hasta el momento. El último satélite de esta serie, el LANDSAT 8 <sup>1</sup> (ver figura 2.4), comenzó sus operaciones normales el 30 de mayo del 2013 y sigue en funcionamiento en la actualidad.

A partir de los satélites LANDSAT, el interés de la comunidad científica internacional y la sociedad en general por la teledetección ha crecido exponencialmente, contándose por miles los estudios realizados con las imágenes que proporcionan los satélites. Nuevas misiones y proyectos se diseñaron y continúan desarrollándose para la observación terrestre (Referencia [16]).

---

<sup>1</sup>Se puede encontrar información acerca del Satélite LANDSAT 8 en la página web [http://www.nasa.gov/mission\\_pages/landsat/main/](http://www.nasa.gov/mission_pages/landsat/main/).

## 2.3. Elementos del Proceso de Teledetección

Los elementos involucrados en un proceso de teledetección desde satélites se muestran en la Figura 2.5. El primer requerimiento supone disponer de una fuente de energía que ilumine o provea energía al objeto de interés (cultivo, bosque, mar, ciudad, etc.). El caso más habitual consiste en que esa fuente sea el Sol (A). La radiación solar, en su «viaje» hacia la Tierra, atraviesa e interacciona con la atmósfera (B). Una vez alcanza la superficie terrestre interactúa con los objetos que en ella se encuentran. La radiación reflejada dependerá de las características de esos objetos, permitiendo distinguir a unos de otros (C). Un sensor a bordo de un satélite recoge y graba esa radiación reflejada por la superficie terrestre y la propia atmósfera (D).

La energía captada por el sensor se transmite a una estación de recepción y procesamiento donde los datos se convierten en imágenes digitales (E). La imagen procesada se interpreta, visualmente y/o digitalmente, para extraer información acerca de los objetos que fueron iluminados (F). El paso final del proceso de teledetección consiste en aplicar la información extraída de la imagen para conseguir un mejor conocimiento de la zona de estudio, revelando nuevas informaciones o ayudándonos a resolver un problema particular (G) (Referencia [16]).

**Figura 2.5:** Elementos de un Proceso de Teledetección desde Satélites.

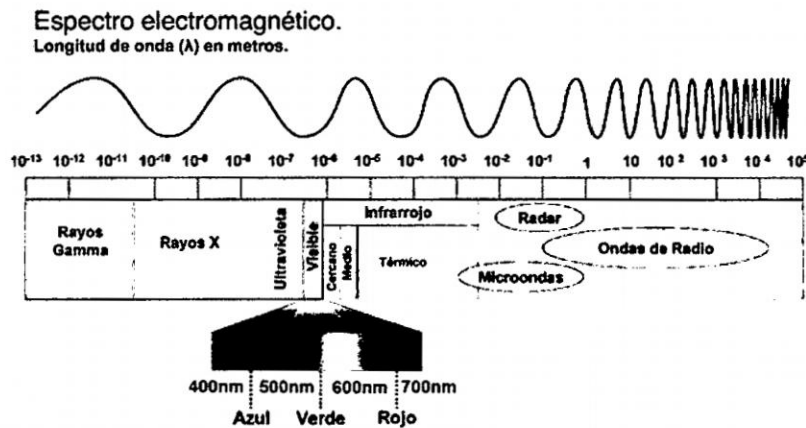


**Fuente:** Elaboración Propia.

## 2.4. El Espectro Electromagnético

Los ojos de los seres humanos se pueden considerar como sensores remotos ya que detectan la luz reflejada por los objetos de nuestro entorno. Sin embargo, la visión humana sólo es capaz de percibir una pequeña parte del espectro electromagnético, el visible.

Figura 2.6: Espectro Electromagnético.



Fuente: Referencia [10].

La luz visible es sólo una de las muchas formas de radiación electromagnética que existen. Así, las ondas de radio, el calor, los rayos ultravioleta o los rayos X son otras formas comunes. En teledetección, lo normal es caracterizar a las ondas electromagnéticas por su longitud de onda en micrómetros ( $\mu m$ ,  $10^{-6}m$ ) o nanómetros ( $nm$ ,  $10^{-9}m$ ), es decir, por la posición que ocupan dentro del espectro electromagnético. De esta forma quedan definidas varias regiones del espectro. Aunque por conveniencia se le asignan diferentes nombres a estas regiones (ultravioleta, visible, infrarrojo, microondas, etc.), no existen divisiones exactas entre unas y otras (ver figura 2.6).

Los sensores montados a bordo de los satélites de teledetección son capaces de detectar y grabar radiaciones de las regiones no visibles del espectro electromagnético, desde el ultravioleta hasta las microondas (Referencia [16]).

El visible (VIS) es una pequeña región del espectro electromagnético que apenas abarca desde los  $0.4 \mu m$  hasta los  $0.7 \mu m$ . El color azul iría desde  $0.4$  hasta  $0.5 \mu m$ , el


verde desde  $0.5 \mu m$  hasta  $0.6 \mu m$  y el rojo de  $0.6 \mu m$  a  $0.7 \mu m$ . La energía ultravioleta (UV) se encuentra inmediatamente por debajo del color azul. Por encima del rojo se sitúa la región infrarroja (IR), que a su vez está dividida en tres categorías: IR próximo (NIR) ( $0.7 - 1.3 \mu m$ ), IR medio (SWIR) ( $1.3 - 3 \mu m$ ) e IR térmico (TIR) ( $3 - 100 \mu m$ ). La porción de microondas se encuentra más allá del IR, a longitudes de onda mucho más grandes ( $1 mm - 1 m$ ), que son las longitudes de onda más largas usadas en teledetección. De éstas, las más cortas tienen propiedades similares al IR térmico, mientras que las restantes son similares a las usadas en comunicaciones (Referencia [10]). En la actualidad existen discrepancias entre los científicos que usan las técnicas de teledetección en microondas y los encargados de establecer la asignación de frecuencias para las telecomunicaciones, ya que hay una gran competencia por determinar qué uso se le da a determinadas longitudes de onda dentro de esta región del espectro electromagnético.

## 2.5. Reflectancia de las superficies terrestres

La reflectancia espectral es una característica de las superficies terrestres, algo fundamental en teledetección. Se define como la proporción de energía incidente que es reflejada por una superficie. Por lo tanto, es una magnitud adimensional que puede tomar valores entre 0 y 1 ó porcentajes entre 0 y 100 %. Para una determinada superficie este parámetro varía en función de la longitud de onda. Al gráfico de la reflectancia espectral frente a la longitud de onda se le denomina curva de reflectancia espectral o firma espectral (ver figura 2.7). La configuración de éstas curvas permite extraer las características espectrales de una superficie y tiene una gran influencia sobre la elección de la región espectral en la cual los datos de teledetección se deben adquirir para una aplicación particular (Referencia [16]).

Así, por ejemplo, las curvas de reflectancia espectral para la vegetación casi siempre manifiestan los picos y valles que se muestran en la figura 2.7. Los valles en la región del visible vienen dados por los pigmentos en las hojas de las plantas.

Figura 2.7: Curvas de Reflectancia Espectral.



Fuente: Referencia [8].

La clorofila absorbe energía fuertemente en las bandas centradas en 0.45 y 0.67  $\mu m$ . Es por ello que nuestros ojos perciben la vegetación sana de color verde, debido a la gran absorción en azul y rojo por las hojas y la reflexión en el verde. Cuando la vegetación no está sana, disminuye la clorofila, y el resultado es un incremento de la reflectancia espectral en el rojo, por lo que las hojas se ven con un tono amarillento (mezcla de verde y rojo). Al llegar al IR próximo la reflectancia de la vegetación sana aumenta drásticamente. La región 0.7-1.3  $\mu m$  refleja entre el 40 y el 50 % de la energía incidente. El resto de la energía es transmitida casi en su totalidad, ya que en esta región la absorción es menor al 5%. La reflectancia de 0.7 a 1.3  $\mu m$  es función de la estructura interna de las hojas. Como estas son distintas, nos permite diferenciar distintos tipos de vegetación, aunque en el visible sean muy similares. Más allá de 1.3  $\mu m$  la reflectancia de las hojas es inversamente proporcional a su contenido de agua total, por lo que esta región del espectro es útil para detectar estrés hídrico en la vegetación.

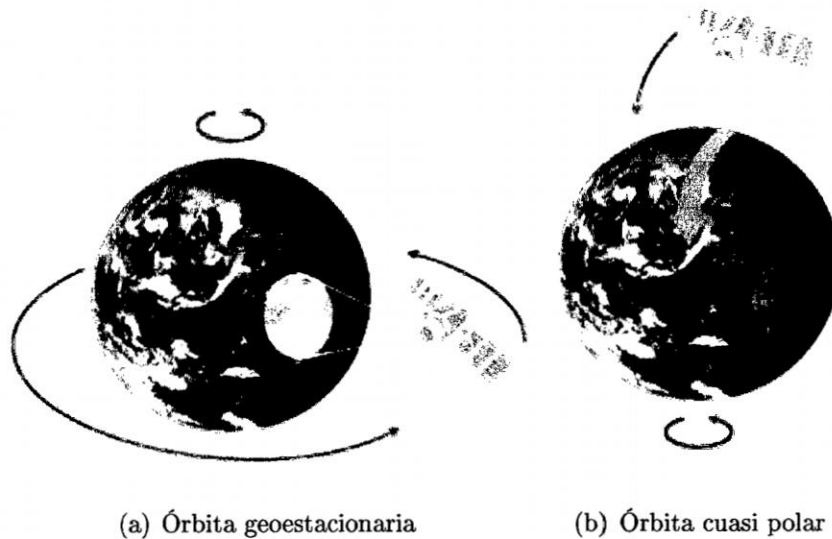
Los suelos casi no presentan variación en la reflectancia a lo largo de todo el espectro electromagnético (Figura 2.7). Los principales factores que la afectan son: humedad, textura, rugosidad, presencia de óxidos de hierro y materia orgánica. La presencia de humedad hace decrecer la reflectancia, al igual que la rugosidad, la materia orgánica y la presencia de óxidos de hierro, estos últimos principalmente en el visible.

## 2.6. Características orbitales de los satélites de teledetección

Se denomina órbita a la trayectoria seguida por un satélite alrededor de la Tierra. Ésta depende de las características y objetivos de los sensores que van a bordo del satélite (Referencia [22]). En general, las órbitas quedan definidas por la altitud, orientación y rotación con respecto a la Tierra.

Las órbitas geoestacionarias son aquellas que describen los satélites que están situados a grandes alturas y siempre ven la misma porción de superficie terrestre (ver figura 2.8 - izquierda). Su altura suele ser de 36.000 km y se mueven a una velocidad angular igual a la de la rotación de la Tierra, por lo que siempre permanecen en la misma posición relativa respecto a la superficie terrestre. Satélites meteorológicos como el METEOSAT tienen este tipo de órbitas (Referencia [22]).

**Figura 2.8:** Órbita de los satélites de Teledetección.



Fuente: Referencia [8].

Sin embargo, la mayor parte de los satélites de teledetección se diseñan para seguir una órbita de norte a sur, la cual, en conjunción con la rotación de la Tierra (de oeste a este), les permite cubrir la mayor parte de la superficie terrestre durante un cierto periodo de tiempo. A estas órbitas se les ha dado el nombre de cuasi

polares, por la inclinación relativa con respecto a una línea trazada entre los polos norte y sur (ver figura 2.8 - derecha). Además, muchos de los satélites de órbita cuasi polar también son heliosíncronos, ya que cubren la misma área del mundo a una hora local fija del día, llamada hora solar local. Esto significa que, a una latitud dada, la posición del Sol en el cielo, al igual que la posición del satélite que pasa por encima, será aproximadamente la misma dentro de la misma estación del año. Este hecho asegura condiciones de iluminación similares cuando se adquieren imágenes en una estación específica durante diferentes años, o en un área particular sobre una serie de días. Esta cuestión resulta fundamental para monitorizar cambios entre imágenes o para hacer mosaicos juntando imágenes adyacentes, al no tener que ser corregidas por diferentes condiciones de iluminación (Referencia [16]).

En el movimiento alrededor de la Tierra, el satélite sólo registra información de una porción de la misma. El ancho de la franja en la superficie terrestre que es capaz de registrar se denomina ancho de barrido (ver figura 2.9). Este puede variar desde decenas a cientos de kilómetros, dependiendo del tipo de sensor y de la altura del satélite. Esta característica determinará en muchos satélites la capacidad para captar, en una sola pasada, un área determinada. Si el ancho del área a registrar es superior al ancho de barrido, la imagen no podrá ser captada en una sola toma y habrá que esperar a un segundo pase (Referencia [22]).

**Figura 2.9:** Ancho de barrido.



**Fuente:** Referencia [8].


## 2.7. Resolución de los sensores remotos

Los sensores instalados en los satélites de teledetección poseen una serie de particularidades que determinan las características de las imágenes que van a proporcionar. Estas características vienen definidas básicamente por diferentes tipos de resolución:

### 2.7.1. Resolución espacial

La resolución espacial es una medida de la distancia angular o lineal más pequeña que puede captar un sensor remoto de la superficie de la Tierra (Referencia [16]), y viene representada por un píxel. Un píxel es la unidad mínima que conforma una imagen digital (ver figura 2.10). Cada píxel representa un área de la superficie terrestre. Los tonos de gris de cada píxel hacen referencia a distintos niveles de energía detectada.

**Figura 2.10:** Formato de una imagen digital (7 x 9 píxeles).



Fuente: Referencia [8].

El píxel es generalmente de forma cuadrada, por lo que la longitud medida sobre el terreno de un lado del píxel define la resolución espacial del sensor. La resolución espacial de un sensor se suele expresar en metros o metros/píxel.

Son varios los factores que determinan la resolución espacial de un sensor remoto (distancia sensor-superficie terrestre, ángulo de visión y campo de visión instantá-

neo). Para el caso de los sensores a bordo de satélites estos factores son prácticamente fijos, por lo que la resolución espacial puede ser considerada constante, siempre y cuando el ángulo de visión no sea grande (Referencia [22]).

Cuanto mayor sea la resolución espacial, es decir, menor superficie represente un píxel de la imagen, más pequeños serán los objetos que se pueden distinguir en la superficie y viceversa.

Para que un objeto homogéneo pueda ser detectado, su tamaño tiene que ser generalmente igual o más grande que la superficie de terreno que representa un píxel. Si el objeto es más pequeño puede que no sea detectado y el sensor grabará un promedio de todo lo que haya dentro (Referencia [16]). Sin embargo, algunas veces se detectan objetos muy pequeños porque su reflectancia domina dentro de la superficie del píxel.

### **2.7.2. Resolución espectral**

Las distintas superficies responden de manera diferente a la radiación electromagnética. Esto significa que se puede obtener una firma espectral específica para cada superficie. Así, los diferentes tipos de superficie, naturales o no, se pueden identificar en base a sus firmas espectrales (ver figura 2.7), pero será necesario que el espectro sea suficientemente detallado en términos de intervalos de longitud de onda y que cubra un rango espectral ancho (Referencia [16]).

### **2.7.3. Resolución radiométrica**

La resolución radiométrica de los datos de teledetección se define como la cantidad mínima de energía requerida para incrementar el valor de un píxel en un nivel digital (ND) (Referencia [16]).

Asimismo, se define la amplitud o extensión radiométrica como el intervalo dinámico, o máximo número de niveles digitales, que pueden ser detectados por un sensor particular.


La resolución radiométrica en imágenes digitales es comparable al número de

tonos de gris en una fotografía en blanco y negro, ya que ambos se relacionan con el contraste. El ojo humano solo es capaz de percibir aproximadamente 30 tonos de gris diferentes, lo que implica que normalmente la información visual en las imágenes digitales es menor a la que realmente contienen.

#### 2.7.4. Resolución temporal

La resolución temporal es el ciclo de repetición, o intervalo de tiempo, entre dos adquisiciones de imágenes sucesivas de una misma porción de la superficie y depende, en gran medida, de las características orbitales del satélite (Referencia [16]). Muchas veces también se la denomina periodo de revisita. Normalmente los satélites meteorológicos tienen una frecuencia diaria (NOAA) o incluso menor (METEOSAT), mientras que la de los satélites de recursos naturales (tipo LANDSAT) es de 16 a 18 días (Referencia [22]). Sin embargo, muchos satélites actuales tienen la capacidad de reorientar el sensor (ver figura 2.11), lo que les permite aumentar su frecuencia de revisita para una zona determinada, muy importante en el seguimiento de desastres naturales o para detectar procesos que tienen poca perdurabilidad en el tiempo.

**Figura 2.11:** Mayor resolución temporal gracias a la reorientación de sensores en pases consecutivos.



Fuente: Referencia [8].

## **2.8. Tipos de imágenes de teledetección**

El tipo de producto más común que suministran los satélites de teledetección es una imagen digital tipo raster (ver figura 2.10), donde cada píxel tiene asignado uno o varios valores numéricos (niveles digitales) que hacen referencia a la energía media recibida dentro de una determinada banda espectral. Teniendo esto en cuenta, se pueden adquirir los siguientes tipos de imágenes:

### **2.8.1. Imagen multiespectral (MS).**

Imagen que lleva asociados varios valores numéricos a cada píxel, tantos como bandas espectrales sea capaz de detectar el sensor . A priori, es el tipo de producto más útil ya que nos proporciona, en cierto modo, la firma espectral de los distintos elementos presentes en la imagen (Referencia [16]). Así, por ejemplo, el satélite IKONOS proporciona una imagen multiespectral con 4 bandas, que cubren las regiones espectrales correspondientes al azul, verde, rojo e infrarrojo próximo. Cuanto mayor sea el número de bandas que proporciona el sensor, mayor será la capacidad de análisis de los elementos presentes en la imagen (Referencia [22]).

### **2.8.2. Imagen pancromática (PAN).**

Dispone de una sola banda espectral que abarca comúnmente gran parte del visible y comienzo del infrarrojo, obteniendo como resultado una imagen que habitualmente se representa en una escala de grises (imagen en blanco y negro). Como contrapartida, tienen la ventaja de poseer mayor resolución espacial que las multiespectrales que proporciona el mismo satélite. Es por ello que son muy interesantes para la detección de pequeños elementos de la superficie terrestre que no son distinguibles en la imagen multiespectral (Referencia [16]).

### **2.8.3. Imagen fusionada (PS).**

Este tipo de imagen se obtiene mediante la fusión de una imagen multiespectral con una pancromática. Las siglas PS provienen de pan-sharpened, su denominación en inglés. Básicamente, consiste en asignar a cada píxel de la imagen pancromática los valores procedentes de un algoritmo que combina la imagen pancromática con la multiespectral. El resultado final es una imagen multiespectral con la resolución espacial de la pancromática. El inconveniente de este tipo de imágenes es que se modifica la información espectral original captada por los sensores a través de los algoritmos usados, por lo que se suelen utilizar únicamente como herramientas de interpretación visual y no para análisis espectral. Esta fusión se encuentra dentro de la oferta de los distribuidores oficiales de los satélites capaces de obtener una imagen multiespectral y pancromática. Dicha fusión, con el software adecuado, puede ser realizada por los usuarios (Referencia [16]).

### **2.8.4. Imagen estéreo.**

En realidad se refiere a dos imágenes de una misma zona tomadas con ángulos de visión distintos. Muchos satélites tienen la capacidad de reorientar el sensor, lo que les permite tomar, en una o en sucesivas pasadas, este tipo de imágenes (Referencia [16]). Se suelen emplear para generar modelos de elevación del terreno (Referencia [22]).

# Capítulo 3

## Precipitación (Meteorología)


### 3.1. Introducción

En meteorología, la precipitación es cualquier forma de hidrometeoro que cae de la atmósfera y llega a la superficie terrestre. Este fenómeno incluye lluvia, llovizna, nieve, aguanieve, granizo, pero no virga, neblina ni rocío, que son formas de condensación y no de precipitación. La cantidad de precipitación sobre un punto de la superficie terrestre es llamada pluviosidad, o monto pluviométrico (Referencia [2]).

La precipitación es una parte importante del ciclo hidrológico, responsable del depósito de agua dulce en el planeta y, por ende, de la vida en nuestro planeta, tanto de animales como de vegetales, que requieren del agua para vivir. La precipitación es generada por las nubes, cuando alcanzan un punto de saturación; en este punto las gotas de agua aumentan de tamaño hasta alcanzar el punto en que se precipitan por la fuerza de gravedad (Referencia [2]). Es posible inseminar nubes para inducir la precipitación rociando un polvo fino o un químico apropiado (como el nitrato de plata) dentro de la nube, acelerando la formación de gotas de agua e incrementando la probabilidad de precipitación, aunque estas pruebas no han sido satisfactorias, prácticamente en ningún caso (Referencia [21]).

Si bien la lluvia es la más frecuente de las precipitaciones (ver figura 3.1), no deben olvidarse los otros tipos: la nevada y el granizo. Cada una de estas precipitaciones puede a su vez clasificarse en diversos tipos.

**Figura 3.1:** Precipitación en estado líquido y en forma de un chubasco.



**Fuente:** Referencia [2].

## 3.2. Ciencia de la Medición de la Precipitación

El agua, la principal razón para la vida en la Tierra continuamente circula a través de uno de los sistemas más poderosos de la Tierra: el ciclo del agua (ver figura 3.2). El agua fluye interminablemente entre los océanos, la atmósfera y el suelo. La precipitación en forma de lluvia, nieve, cellisca o granizo, por ejemplo, es un componente vital del ciclo del agua y afecta a todos en la Tierra. Mientras se hacen sentir los efectos de la precipitación a escala local, la comprensión del ciclo del agua de la Tierra y como interactúa con otros sistemas de la Tierra requiere de una visión global. La distribución del agua a través de la atmósfera y cómo se mueve, cambiante entre sus formas sólidas, líquidas y gaseosas, es un vehículo poderoso para la redistribución de la energía en la Tierra e influencia el comportamiento del tiempo del planeta, el clima y otros sistemas ambientales.

La energía, en la forma de calor latente, es absorbida o liberada cuando el agua se somete a un cambio de fase. Por ejemplo, cuando el vapor de agua en la atmósfera se condensa en forma de nubes de calor latente se libera calentamiento de la atmósfera. Inversamente, cuando el agua líquida en la atmósfera se evapora, tal como cuando se mueve la lluvia a través de una capa de aire seco, calor latente de refrigeración se absorbe de la atmósfera. El calor latente impulsa la circulación atmosférica y desempeña un papel importante en la formación de nubes y el desarrollo

**Figura 3.2: El Ciclo del Agua.**



**Fuente:** Página Web del TRMM.

de tormentas.

Sucesivamente, éstas nubes y tormentas producen precipitaciones sobre el suelo y océanos, influyendo en nuestra vida día a día. Desde llovizna o nieve en un viaje por la mañana, a las inundaciones respectivas causadas por tormentas, precipitaciones entre cuencas locales y contribuye al suministro de agua, donde se necesita agua dulce para beber, la agricultura, la industria y el medio ambiente.

Para estudiar las relaciones fundamentales y efectos de la precipitación, los científicos estudian la humedad y la precipitación en la atmósfera. El agua, en todas sus formas, es difícil de medir consistentemente en todo el mundo. Lluvia, nieve y otros tipos de precipitación, tal como granizo y cellisca, varían mucho sobre la Tierra y los océanos. Obteniendo mediciones en Tierra confiables de las precipitaciones, de pluviómetros por ejemplo, a menudo presenta un reto debido a las grandes brechas entre los instrumentos de vigilancia en la Tierra, y las brechas aún más grandes sobre los océanos.

Las observaciones por satélite desde el espacio, sin embargo, cubren áreas amplias y proporcionan mediciones más frecuentes que ofrecen ideas sobre cuándo, dónde y cuánto llueve o nieva en todo el mundo. Satélites de observación terrestre

llevan numerosos instrumentos diseñados para observar características atmosféricas específicas, tales como gotas de agua y partículas de hielo. Estas observaciones son lo suficientemente detalladas para permitir a los científicos distinguir entre lluvia, nieve y otros tipos de precipitaciones, así como observar la estructura, intensidad y dinámica de las tormentas. Estos datos también se introducen en los modelos de predicción del clima que los meteorólogos utilizan para emitir alertas meteorológicas.<sup>1</sup>.

### 3.3. Medición de la precipitación

Los valores de precipitación, para que sean válidos, deben ser científicamente comparables.

Los instrumentos más frecuentemente utilizados para la medición de la lluvia y el granizo son los pluviómetros y pluviógrafos, estos últimos se utilizan para determinar las precipitaciones pluviales de corta duración y alta intensidad. Estos instrumentos deben ser instalados en locales apropiados donde no se produzcan interferencias de edificaciones, árboles, o elementos orográficos como rocas elevadas (Referencia [4]).

La precipitación pluvial se mide en mm, que equivale al espesor de la lámina de agua que se formaría, a causa de la precipitación, sobre una superficie plana e impermeable (Referencia [4]).

A partir de 1980 se está popularizando cada vez más la medición de la lluvia por medio de un radar meteorológico, los que generalmente están conectados directamente con modelos matemáticos que permiten determinar la lluvia en una zona y los caudales en tiempo real, en una determinada sección de un río en dicha zona (Referencia [5]).

A continuación se muestra una breve descripción de la evolución de los sistemas utilizados para realizar la medición de las precipitaciones.


---

<sup>1</sup>Traducido e interpretado de la página web del GPM (Misión de la medición de la Precipitación Global). Para mayor información visitar la página web del GPM <http://pmm.nasa.gov/GPM>

### 3.3.1. Pluviómetro

Aparato destinado a medir la cantidad de agua caída, ya sea en forma de lluvia, nieve o granizo, expresada a través de la cantidad de litros o milímetros caídos por metro cuadrado. Cualquier recipiente de boca ancha, cuya superficie sea conocida puede servir como pluviómetro; para efectuar las medidas, se utilizará una probeta graduada que dará los  $\text{cm}^3$  de precipitación caídos en el pluviómetro. El pluviómetro tipo Hellmann es el instrumento meteorológico más generalizado (ver figura 3.3) (Referencia [4]).

**Figura 3.3:** Pluviómetro.



**Fuente:** Referencia [2].

### 3.3.2. Puviógrafo

Es un instrumento registrador que mide la cantidad de precipitación e indica la intensidad caída. Constituidos por recipientes dobles de medida conocida (vaciado automático). El movimiento se transmite a una plumilla que inscribe sobre la banda registradora el número de vuelcos que se han producido. El gráfico que se genera se conoce como pluviograma (ver figura 3.4).

**Figura 3.4:** Pluviógrafo.




**Fuente:** Referencia [2].

### **3.3.3. Estaciones automáticas**

Registran parámetros hasta cada minuto y a un bajo costo. Pueden verse los datos en tiempo real. El Proceso se hace mediante un programa especializado (ver figura 3.5).

**Figura 3.5:** Estación automática de precipitación.




**Fuente:** Referencia [2].

### **3.3.4. Radar**

Puede determinar dónde están la lluvia y el granizo. El radar rebota ondas de radio en las gotas de lluvia de las nubes. Una computadora mide cuánto tiempo

le toma a las ondas reflejarse de vuelta y utiliza ese tiempo para determinar cuán lejos está la lluvia. La computadora también mide cuánta energía se refleja de vuelta hacia el radar y calcula cuanta lluvia contienen las nubes (ver figuras 3.6 y 3.7).

**Figura 3.6:** El Radar NPOL de la NASA.



**Fuente:** Referencia [21].

**Figura 3.7:** Micro Radar de precipitación.




**Fuente:** Referencia [21].

### 3.3.5. Radar Doppler

No sólo puede determinar cuán lejos están las gotas de lluvia, también puede calcular si se están moviendo en dirección o lejos del radar. Los metereólogos saben que si la lluvia se está moviendo, el viento debe estar empujándola. Es así como saben hacia dónde sopla el viento dentro de las nubes (ver figura 3.8).

**Figura 3.8:** El Radar Doppler de la NASA.



**Fuente:** Referencia [21].

### 3.4. Origen de la precipitación

En esencia toda precipitación de agua en la atmósfera, sea cual sea su estado (sólido o líquido) se produce por la condensación del vapor de agua contenido en las masas de aire, que se origina cuando dichas masas de aire son forzadas a elevarse y enfriarse (Referencia [4]). Para que se produzca la condensación es preciso que el aire se encuentre saturado de humedad y que existan núcleos de condensación (Referencia [21]).

- El aire está saturado si contiene el máximo posible de vapor de agua. Su humedad relativa es entonces del 100 por 100. El estado de saturación se alcanza normalmente por enfriamiento del aire, ya que el aire frío se satura con menor cantidad de vapor de agua que el aire caliente. Así, por ejemplo, 1 m<sup>3</sup> de aire a 25 °C de temperatura, cuyo contenido en vapor de agua sea de 11 g, no está saturado; pero los 11 g lo saturan a 10 °C, y entonces la condensación ya es posible.
- Los núcleos de condensación (que permiten al vapor de agua recuperar su estado líquido), son minúsculas partículas en suspensión en el aire: partículas que proceden de los humos o de microscópicos cristales de sal que acompañan a la evaporación de las nieblas marinas. Así se forman las nubes. La pequeñez

de las gotas y de los cristales les permite quedar en suspensión en el aire y ser desplazadas por los vientos. Se pueden contar 500 por  $\text{cm}^3$  y, sin embargo, 1  $\text{m}^3$  de nube apenas contiene tres gramos de agua<sup>2</sup>.

Las nubes se resuelven en lluvia cuando las gotitas se hacen más gruesas y más pesadas. El fenómeno es muy complejo: las diferencias de carga eléctrica permiten a las gotitas atraerse; los «núcleos», que a menudo son pequeños cristales de hielo, facilitan la condensación. Así es como las descargas eléctricas se acompañan de violentas precipitaciones. La técnica de la «lluvia artificial» consiste en «sembrar» el vértice de las nubes, cuando hay una temperatura inferior a 0 °C, con yoduro de sodio; éste se divide en minúsculas partículas, que provocan la congelación del agua; estos cristales de hielo se convierten en lluvia cuando penetran en aire cuya temperatura es superior a 0 °C (Referencia [5]).

### 3.5. Variación temporal de la precipitación

Las precipitaciones varían de acuerdo a ciertos ciclos temporales determinados por los movimientos de rotación y traslación terrestres y por la localización astronómica o geográfica del lugar de que se trate. Esos ciclos pueden ser: diarios, mensuales o estacionales o en ciclos anuales, en efecto, siempre hay meses en que las precipitaciones son mayores que en otros. Por ejemplo, en San Francisco (California - Estados Unidos), los meses de mayores precipitaciones se dan entre noviembre y marzo, mientras que en Miami (Florida) los meses de mayor precipitación son de mayo a octubre (Referencia [21]).

Para poder evaluar correctamente las características objetivas del clima, en el cual la precipitación, y en especial la lluvia, desempeña un papel muy importante, las precipitaciones mensuales deben haber sido observadas por un período de por lo menos 20 a 30 años, lo que se llama un período de observación largo (Referencia [4]).

---

<sup>2</sup>Más información sobre precipitación puede encontrarse en la siguiente página web <http://en.wikipedia.org/wiki/Precipitation>

La variación estacional de las precipitaciones, en especial de la lluvia, define el año hidrológico. Éste da inicio en el mes siguiente al de menor precipitación media de largo período. Por ejemplo en San Francisco (California), el año hidrológico se inicia en agosto, mientras que en Miami (Florida) se inicia en enero (Referencia [5]).

### **3.6. Variación espacial de la precipitación**

La distribución espacial de la precipitación sobre los continentes es muy variada, así existen extensas áreas como los desiertos, donde las precipitaciones son extremadamente escasas, del orden 0 a 200 mm de precipitación por año (Referencia [5]). En el desierto del Sahara la media anual de lluvia es de apenas algunos mm, mientras que en las áreas próximas al Golfo de Darién entre Colombia y Panamá, la precipitación anual es superior a 3.000 mm, con un máximo de unos 10 metros (10.000 mm). El desierto de Atacama en el norte de Chile, es el área más seca de todos los continentes. La orografía del terreno influye fuertemente en las precipitaciones. Una elevación del terreno provoca muy frecuentemente un aumento local de las precipitaciones, al provocar la ascensión de las masas de aire saturadas de vapor de agua (lluvias orográficas) (Referencia [21]).

### **3.7. Altura de precipitación**

Para realizar mediciones, se comprobaría la altura del agua de lluvia que cubriría la superficie del suelo, en el área de influencia de una estación pluviométrica, si pudiese mantenerse sobre la misma sin filtrarse ni evaporarse (Referencia [4]). Se expresa generalmente en mm. La medición de la precipitación se efectúa por medio de pluviómetros o pluviógrafos, los segundos son utilizados principalmente cuando se trata de determinar precipitaciones intensas de corto período. Para que los valores sean comparables, en las estaciones pluviométricas, se utilizan instrumentos estandarizados (Referencia [5]).

### 3.8. Importancia de las precipitaciones en la ingeniería

Muchas obras de ingeniería civil son influenciadas profundamente por factores climáticos, por su importancia destacan las precipitaciones pluviales. En efecto, un correcto dimensionamiento del drenaje garantizará la vida útil de una carretera, una vía férrea, un aeropuerto. El conocimiento de las precipitaciones pluviales extremas y en consecuencia el dimensionamiento adecuado de las obras hidráulicas, así por ejemplo los vertedores de excedencias de las presas, garantizará su correcto funcionamiento y la seguridad de las poblaciones que se sitúan aguas abajo. El cálculo de las lluvias extremas, de corta duración, es muy importante para dimensionar el drenaje urbano, y así evacuar volúmenes de agua que podrían producir inundaciones (Referencia [21]).

Las características de las precipitaciones pluviales que se deben conocer para estos casos son:

La **intensidad de la lluvia** y **duración de la lluvia**: estas dos características están asociadas. Para un mismo período de retorno, al aumentarse la duración de la lluvia disminuye su intensidad media, la formulación de esta dependencia es empírica y se determina caso por caso, con base a los datos observados directamente en el sitio de estudio o en otros sitios próximos con las características hidrometeorológicas similares (Referencia [5]). Dicha formulación se conoce como relación Intensidad-Duración-Frecuencia o comúnmente conocidas como curvas IDF. Las precipitaciones pluviales extremas período de retorno de 2, 5, 10, 20, 50, 100, 500, 1000 y hasta 10000 años, para cada sitio particular o para una cuenca, o la precipitación máxima probable, o PMP, son determinadas con procedimientos estadísticos, con base a extensos registros de lluvia.

### 3.9. Cálculo de la lluvia media en una cuenca

Las dimensiones de una cuenca hidrográfica son muy variadas y las precipitaciones también varían en el tiempo y en el espacio. Para tomar en cuenta éstas diversidades y conocer el comportamiento de las lluvias, así como su magnitud en tales condiciones, es frecuente que en la misma se instalen varias estaciones pluviométricas (Referencia [4]). Para determinar la precipitación media en la cuenca se elige un período de retorno determinado, se determina la lluvia en cada estación para el periodo de retorno seleccionado y luego se calcula la lluvia media, para esto se utiliza alguno de los procedimientos siguientes: método aritmético, polígonos de Thiessen y método de las isoyetas (Referencia [5]). Es común encontrar regiones sin registros o con escasa información, por lo que se debe recurrir a criterios de evaluación regional. La hipótesis de la regionalización es que las lluvias importantes se presentaron en sitios próximos, lo cual genera la ventaja de aprovechar los datos de las estaciones donde si se registraron aquellos eventos.

## Capítulo 4

# Redes de Neuronas Artificiales

En cierta forma este capítulo representa una reproducción elemental de la literatura existente en el campo de las Redes de Neuronas Artificiales. Bajo estas premisas nuestro trabajo en este capítulo estará limitado a presentar las teorías exclusivamente necesarias para el desarrollo de la presente tesis. Para intereses similares haremos las referencias específicas y detalladas en donde se trate del tema con mayor extensión.

### 4.1. Introducción a las Redes de Neuronas Artificiales

Uno de los grandes enigmas que ha preocupado al hombre desde tiempos ancestrales es el de su propia naturaleza. Cuáles son las características que nos hacen humanos, qué tiene el hombre que no tienen el resto de los animales, qué nos hace únicos entre todos los seres vivos. Este enigma ha venido asociado con el de la inteligencia, pues dentro de la naturaleza humana está el ser inteligente, y ésta es una característica que discrimina absolutamente a nuestra especie (Referencia [8]).

A medida que la ciencia y la tecnología han ido avanzando, el objetivo se ha ido perfilando: uno de los retos más importantes a los que se enfrenta el ser humano de nuestra generación es el de la construcción de sistemas inteligentes. Aquí, sistema puede ser entendido como cualquier dispositivo físico o lógico capaz de realizar la

tarea requerida. Éste es precisamente el objetivo de la disciplina científica conocida con el nombre de Inteligencia Artificial (Referencia [17]).

Dentro de la Inteligencia Artificial se pueden distinguir dos grandes áreas. Una se ocupa de la construcción de sistemas con características que se puedan definir como inteligentes. A este campo se lo denomina Inteligencia Artificial Simbólica. En la Inteligencia Artificial Simbólica se dice que los sistemas siguen un esquema de arriba hacia abajo (en inglés top-down) ya que es necesario disponer de una aproximación a la solución del problema y diseñarla completamente.

Frente a esta perspectiva se encuentra la otra gran área de la Inteligencia Artificial, la Subsimbólica. En este caso no se realizan diseños a alto nivel de sistemas capaces de resolver los problemas utilizando las técnicas de la disciplina, sino que se parte de sistemas genéricos que van adaptándose y construyéndose hasta formar por sí mismos un sistema capaz de resolver el problema (Referencia [8]). El mecanismo fundamental que capacita a los seres vivos para la realización de tareas sofisticadas no preprogramadas directamente es el sistema nervioso. Desde este punto de vista la perspectiva subsimbólica trata de estudiar los mecanismos de los sistemas nerviosos, del cerebro, así como su estructura, funcionamiento y características lógicas, con la intención de diseñar programas basados en dichas características que se adapten y generen sistemas capaces de resolver problemas. En este caso el diseño es de abajo hacia arriba (en inglés bottom-up), ya que los sistemas diseñados son simples e idénticos, recogen las características físicas de los sistemas que tratan de imitar, y se van generando cálculos cada vez más complejos, de forma automática, mediante mecanismos prefijados de aprendizaje. Es en este campo donde se encuentra las Redes de Neuronas Artificiales.

Idealmente, el objetivo de las Redes de Neuronas Artificiales es llegar a diseñar máquinas con elementos neuronales de procesamiento paralelo, de modo que el comportamiento global de esa red “emule”, de la forma más fiel posible, los sistemas neuronales de los animales (Referencia [17]). Esto hace imprescindible el estudio profundo de los mecanismos que rigen el comportamiento de los sistemas neuronales.

### **4.1.1. Fundamentos biológicos de las Redes Neuronales**

El aparato de comunicación neuronal de los animales y del hombre, formado por el sistema nervioso y hormonal, en conexión con los órganos de los sentidos y los órganos efectores (músculos, glándulas), tiene la misión de recoger informaciones, transmitir las y elaborarlas, en parte también almacenarlas y enviarlas de nuevo en forma elaborada (Referencia [8]). El sistema de comunicación neuronal se compone de tres partes:


1. Los receptores, que están en las células sensoriales, recogen las informaciones en forma de estímulos, bien del ambiente, bien del interior del organismo.
2. El sistema nervioso, que recibe las informaciones, las elabora, en parte las almacena y las envía en forma elaborada a los órganos efectores y otras zonas del sistema nervioso.
3. Órganos Diana o efectores (por ejemplo, músculos y glándulas), que reciben la información y la interpretan en forma de acciones motoras, hormonales, etc.

El elemento estructural y funcional más esencial, en el sistema de comunicación neuronal, es la célula nerviosa o neurona. La mayoría de las neuronas utilizan sus productos de secreción como señales químicas (transmisores) para la transmisión de la información. Dicha información se envía, entre las distintas neuronas, a través de prolongaciones, formando redes, en las cuales se elabora y almacena información. Además, una parte de las neuronas está en relación con receptores, a través de los cuales llegan comunicaciones procedentes del exterior o del interior del organismo hasta las redes neuronales (Referencia [12]).

Otra parte conduce las informaciones, elaboradas en forma de órdenes, hacia los efectores. Una de las prolongaciones es la encargada de la conducción de impulsos; se denomina axón.

A una distancia más o menos grande a partir de su origen, se ramifica y forma los botones terminales, que se ponen en contacto con otras neuronas o con células efectoras, pero sin llegar a fusionarse con ellas. A esta zona de contacto se la denomina

**Figura 4.1:** Descripción de una célula nerviosa típica.



**Fuente:** Elaboración Propia.

sinapsis.

La misión de las neuronas comprende generalmente cinco funciones parciales:

- Las neuronas recogen la información que llega a ellas en forma de impulsos procedentes de otras neuronas o de receptores.
- La integran en un código de activación propio de la célula.
- La transmiten codificada en forma de frecuencia de impulsos a través de su axón.
- A través de sus ramificaciones el axón efectúa la distribución espacial de los mensajes.
- En sus terminales transmite los impulsos a las neuronas subsiguientes o a las células efectoras.

Un diagrama de célula nerviosa típica es el que se muestra en la figura 4.1. En este esquema se aprecia que la neurona consta de un cuerpo celular y un núcleo, como el resto de las células del organismo, pero cuenta también con algunos elementos específicos. En primer lugar está el axón, que es una ramificación de salida de la neurona. A través de él se propagan una serie de impulsos electro-químicos. Además, la neurona cuenta con un gran número de ramificaciones de entrada, las dendritas,

que propagan la señal al interior de la neurona. El mecanismo es el siguiente. Las sinapsis recogen información electro-química procedentes de las células vecinas a las que la célula en cuestión está conectada; esta información llega al núcleo donde es procesada hasta generar una respuesta que es propagada por el axón. Más tarde, la señal única propagada por el axón se ramifica y llega a dendritas de otras células a través de los que se denomina sinapsis. Las sinapsis son los elementos de unión entre axón y dendritas. Es un espacio líquido donde existen determinadas concentraciones de elementos ionizados, normalmente iones de sodio y potasio. Estos iones hacen que el espacio intersináptico posea ciertas propiedades de conductividad que activen o impidan, en cierto grado, el paso del impulso eléctrico. De esta forma las sinapsis se convierten en potenciadores o inhibidores de la señal procedente de los axones, actuando como aislantes o amplificadores a conveniencia.

El funcionamiento en general será el de una enorme malla que propaga señales electro-químicas de unas células a otras y que va modificando sucesivamente la concentración de iones de la sinapsis. Esta concentración iónica es muy importante, ya que las neuronas no son elementos lineales; no se encarga simplemente de proyectar la acumulación de las señales recibidas por sus dendritas, sino que funcionan a saturación; producen una señal de activación si la señal recibida supera un cierto umbral, permaneciendo inhibidas mientras tanto (Referencia [8]).

#### **4.1.2. Modelo computacional**

La gran diferencia entre una máquina conexionista, es decir, una máquina neuronal y los programas de computador convencionales es que éstas «elaboran», en cierta medida, la información de entrada para obtener una salida o respuesta. No se trata de la aplicación ciega y automática de un algoritmo. De hecho, el proceso de elaboración de la información recibida depende de las distintas características, tanto estructurales, como funcionales, de la red (Referencia [8]).

Existen modelos muy diversos de redes de neuronas en los cuales se siguen filosofías de diseño, reglas de aprendizaje y funciones de construcción de las respuestas

muy distintas. Una primera clasificación se hace en función del recorrido que sigue la información dentro de la red, y así se distinguen redes alimentadas hacia adelante y redes con retro-alimentación (Referencia [12]).

A continuación se va a describir el modelo computacional general utilizado para desarrollar los diferentes sistemas de Redes de Neuronas Artificiales.

#### 4.1.2.1. La neurona artificial

La neurona artificial, célula o autómatas, es un elemento que posee un estado interno, llamado nivel de activación, y recibe señales que le permiten en su caso, cambiar de estado.

Las neuronas poseen una función que les permite cambiar de nivel de activación a partir de las señales que reciben; a dicha función se le denomina función de transición de estado o función de activación. Las señales que recibe cada neurona pueden provenir del exterior o de las neuronas a las cuales está conectada (Referencia [17]).


El nivel de activación de una célula depende de las entradas recibidas y de los valores sinápticos, pero no de anteriores valores de estados de activación. Para calcular el estado de activación se ha de calcular en primer lugar la entrada total a la célula,  $E_i$ . Este valor se calcula como la suma de todas las entradas ponderadas por ciertos valores.

La figura 4.2 muestra un modelo que representa esta idea. Aquí un grupo de entradas  $x_1, x_2, \dots, x_n$  son introducidas en una neurona artificial. Éstas entradas, definidas por un vector  $\overline{X}$ , corresponden a las señales de las sinapsis de una neurona biológica. Cada señal se multiplica por un peso asociado  $w_1, w_2, \dots, w_n$  antes de ser aplicado el sumatorio etiquetado por  $\Sigma$ . Cada peso corresponde a la fuerza de una conexión sináptica, es decir el nivel de concentración iónica de la sinapsis, y se representa por un vector  $\overline{W}$ .

El sumatorio que corresponde al cuerpo de la neurona, suma todas las entradas ponderadas algebraicamente, produciendo una salida que se denomina  $E$ , así:

$$E = x_1w_1 + x_2w_2 + \dots + x_nw_n$$

**Figura 4.2:** Esquema de una unidad de proceso típica.



**Fuente:** Elaboración Propia.

Esto puede ser definido en forma vectorial como sigue:

$$E = X^T W$$

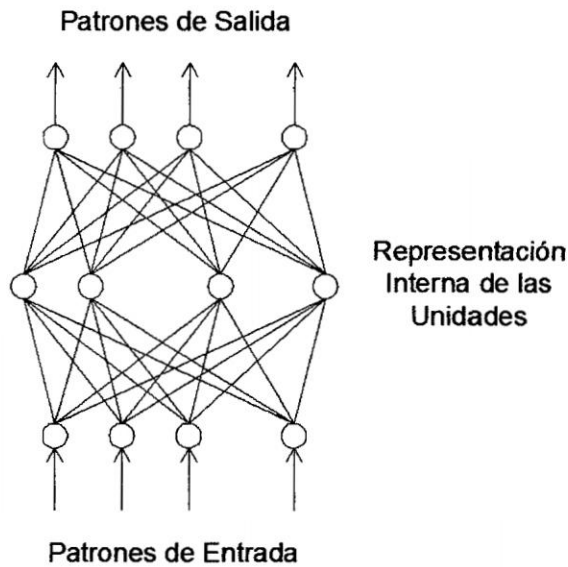
Las señales  $E$  son procesadas además por una función llamada función de activación o de salida  $F$ , que produce la señal de salida de la neurona  $S$ . Dependiendo de la función  $F$ , habrá distintos modelos de autómatas.

#### 4.1.2.2. Estructura básica de la red

En la figura 4.2 se muestra un ejemplo de una unidad típica de proceso de una Red de Neuronas Artificial. A la izquierda se ve una serie de entradas a la neurona; cada una llega de la salida de otra neurona de la red. Una vez calculada la salida de una neurona, como se ha explicado anteriormente, ésta se propaga, vía conexiones de salida, a las células destino. Todas las conexiones de salida reciben el mismo valor de salida.

A la manera en que las células se conectan entre sí se la denomina patrón de conectividad o arquitectura de la red. La estructura básica de interconexión entre células es la de la red multicapa, mostrada en la figura 4.3. Se trata de una estructura típica de implementación del paradigma conocido como RETRO-PROPAGACIÓN. El primer nivel lo constituyen las células de entrada; estas unidades reciben los valores de unos patrones representados como vectores que sirven de entrada a la red. A continuación hay una serie de capas intermedias, llamadas ocultas, cuyas unidades responden a rasgos particulares que pueden aparecer en los patrones de

**Figura 4.3:** Esquema de una red de tres capas totalmente interconectadas.



**Fuente:** Elaboración Propia.

entrada. Puede haber uno o varios niveles ocultos. El último nivel es el de salida. La salida de estas unidades sirve como salida de toda la red (Referencia [17]).

Así pues, una Red de Neuronas Artificial podría definirse como un grafo cuyos nodos están constituidas por unidades de proceso idénticos, y que propagan información a través de los arcos, En este grafo se distinguen tres tipos de nodos: los de entrada, los de salida y los intermedios (Referencia [8]).

#### 4.1.2.3. Aprendizaje

La parte más importante de una Red de Neuronas Artificial es el aprendizaje. El esquema de aprendizaje de una red es lo que determina el tipo de problemas que será capaz de resolver. Las Redes de Neuronas Artificiales son sistemas de aprendizaje basados en ejemplos. Desde el punto de vista de los ejemplos (Referencia [17]), el conjunto de aprendizaje debe poseer las siguientes características:

- Ser significativo. Debe haber un número suficiente de ejemplos. Si el conjunto de aprendizaje es reducido, la red no será capaz de adaptar sus pesos de forma eficaz.

- Ser representativo. Los componentes del conjunto de aprendizaje deberán ser diversos. Si un conjunto de aprendizaje tiene muchos más ejemplos de un tipo que del resto, la red se especializará en dicho subconjunto de datos y no será de aplicación general.

El aprendizaje en una Red de Neuronas 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.

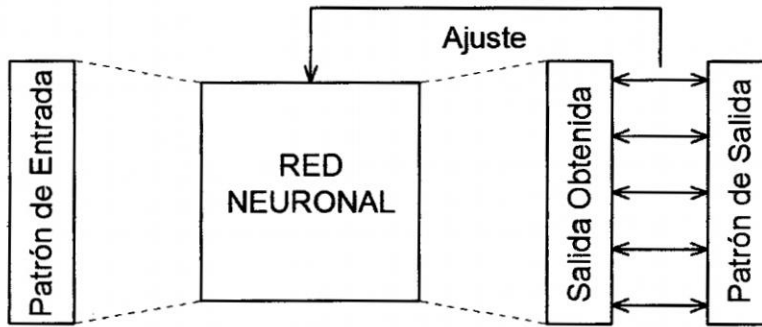
El criterio de convergencia depende del tipo de red utilizado o del tipo de problema a resolver. La finalización del periodo de aprendizaje se puede determinar:

- Mediante un número fijo de ciclos. Se decide a priori cuantas veces será introducido todo el conjunto, y una vez superado dicho número se detiene el proceso y se da por aceptada la red resultante.
- Cuando el error descienda por debajo de una cantidad establecida. En este caso habrá que definir en primer lugar una función de error, bien a nivel de patrón individual, bien a nivel de la totalidad del conjunto de entrenamiento.
- Cuando la modificación de los pesos sea irrelevante. En algunos modelos se define un esquema de aprendizaje que hace que las conexiones vayan modificándose cada vez con menor intensidad.

Dependiendo del esquema de aprendizaje y del problema a resolver, se pueden distinguir tres tipos de esquemas de aprendizaje.


- **Aprendizaje supervisado.** En este tipo de esquemas, los datos del conjunto de aprendizaje tienen dos tipos de atributos: los datos propiamente dichos y cierta información relativa a la solución del problema (Referencia [12]). La manera más habitual de modificar los valores de los pesos de las conexiones es la representada en la figura 4.4.
- **Aprendizaje no supervisado.** En este aprendizaje los datos del conjunto de aprendizaje sólo tienen información de los ejemplos, y no hay nada que

Figura 4.4: Aprendizaje supervisado.



Fuente: Elaboración Propia.

Figura 4.5: Aprendizaje no supervisado.



Fuente: Elaboración Propia.

permita guiar en el proceso de aprendizaje (Referencia [12]). En este caso, no existe profesor externo que determine el aprendizaje. En la figura 4.5 se representa este tipo de aprendizaje.

- **Aprendizaje por refuerzo.** Es una variante del aprendizaje supervisado en el que no se dispone de información concreta del error cometido por la red para cada ejemplo de aprendizaje, sino que simplemente se determina si la salida producida para dicho patrón es o no adecuada (Referencia [12]).

Para el caso de aprendizaje por refuerzo, el aprendizaje tiene una serie de características específicas que es importante resaltar. En este caso el conjunto de aprendizaje está compuesto por ejemplos que contienen los datos y sus salidas deseadas.

Para poder determinar si la red produce salidas adecuadas, se divide el conjunto de entrenamiento en dos conjuntos que se llamarán de entrenamiento y de validación.

El conjunto de entrenamiento se utiliza para aprender los valores de los pesos, como se ha descrito anteriormente. La diferencia es que en vez de medirse el error en el conjunto de entrenamiento, se utiliza el de validación (Referencia [8]).

Para que este proceso sea eficaz los conjuntos de entrenamiento y validación deben tener las siguientes características.

- El conjunto de validación debe ser diferente del de aprendizaje. No puede haber ningún tipo de sesgo en el proceso de selección de los datos de validación.
- El conjunto de validación debe cumplir las propiedades de un conjunto de entrenamiento, descritas anteriormente.

Además, el conjunto de validación puede utilizarse durante el aprendizaje para guiarlo en conjunción con el de entrenamiento. En este caso el proceso sería el siguiente:

1. Asignar a los pesos valores aleatorios.
2. Introducir todos los ejemplos del conjunto de entrenamiento, modificando los pesos de acuerdo con el esquema de aprendizaje supervisado elegido.
3. Introducir todos los ejemplos del conjunto de validación. Obtener el error producido al predecir dichos ejemplos.
4. Si el error calculado en el paso anterior está por encima de cierto valor umbral, ir a (2).
5. Acabar el proceso de aprendizaje y dar como salida la red obtenida.

### **4.1.3. Características de las Redes de Neuronas Artificiales**

#### **4.1.3.1. Redes Neuronales frente a Redes de Neuronas Artificiales**

Una de las diferencias fundamentales entre los Sistemas Biológicos y las Redes de Neuronas Artificiales es la complejidad de la sinapsis. En los sistemas biológicos estos puntos de interconexión tienen miles de componentes y de procesos activos

de propagación de los impulsos electro-químicos. En cambio, las Redes de Neuronas Artificiales tienen conexiones relativamente simples, en las que, por lo general, se realiza una suma ponderada de las entradas, a la que se le aplica una función de umbral, lo que hace casi ridícula la comparación con la complejidad de las sinapsis biológicas (Referencia [8]).

#### **4.1.3.2. Redes de Neuronas Artificiales frente a Computación convencional**

Una CPU clásica es capaz de realizar una centena o más de comandos básicos, incluidas sumas, restas, cargas y desplazamientos, y otras. Estos comandos son ejecutados uno cada vez, en pasos sucesivos de reloj. Por el contrario, una unidad de proceso en Redes de Neuronas Artificiales puede realizar sólo una o unas pocas operaciones diferentes.

Las Redes de Neuronas Artificiales no son programadas, aprenden a partir de ejemplos. Normalmente, a una Red de Neuronas Artificial le presentamos una serie de patrones ejemplo de los cuales ella debe aprender. Estos ejemplos, o patrones de entrenamiento, vienen representados por vectores, y pueden ser obtenidos por fuentes de imágenes, sensores, movimientos del brazo de un robot, etc.

El enfoque de Redes de Neuronas Artificiales no requiere identificación de características, ni el desarrollo de algoritmos y programas para la resolución de problemas particulares; aun así, las Redes de Neuronas Artificiales tienen dos grandes inconvenientes:

- El tiempo de aprendizaje de la red no puede ser conocido a priori. No se puede determinar el número de veces que será necesario introducir todo el conjunto de datos para que la red aprenda.
- El diseño de la red para resolver un problema con éxito puede ser una tarea muy compleja y larga. El método común para diseñar una buena red de neuronas es mediante prueba y error.

Las redes pueden ser entrenadas para resolver problemas de forma genérica, y

no sólo para memorizar los patrones de entrenamiento, siempre que estos patrones representen adecuadamente al problema (Referencia [8]).

## 4.2. Perceptrón Multicapa


Aquí se presenta una de las clases de redes de neuronas, conocida como PERCEPTRON multicapa o red multicapa con conexiones hacia adelante. El PERCEPTRON multicapa es una generalización del PERCEPTRON simple, y surgió como consecuencia de las limitaciones de dicha arquitectura en lo referente al problema de la separabilidad no lineal (Referencia [12]).

La habilidad del PERCEPTRON multicapa para aprender a partir de un conjunto de ejemplos, aproximar relaciones no lineales, etc. hace que sea un modelo adecuado para abordar problemas reales, sin que esto indique que sean los mejores aproximadores universales. Cada una de las clases de aproximadores tienen sus propias características; se conocen ciertas condiciones bajo las cuales un método es preferible a otro, pero en ningún caso se puede decir que un método sea absolutamente el mejor. Serán las consideraciones prácticas de cada problema las que determinen la aproximación de un aproximador u otro (Referencia [8]).

Dentro del marco de las redes de neuronas, el PERCEPTRON multicapa es en la actualidad una de las arquitecturas más utilizadas en la resolución de problemas. Esto es debido, fundamentalmente, a su capacidad como aproximador universal, así como a su fácil uso y aplicabilidad.

Es necesario señalar, sin embargo, que aunque sea una de las redes más conocidas y utilizadas, esto no implica que sea una de las más potentes y con mejores resultados en las diferentes áreas de aplicación. De hecho, el PERCEPTRON multicapa posee también una serie de limitaciones, como el largo proceso de aprendizaje para problemas complejos dependientes de un gran número de variables; la dificultad en ocasiones de codificar problemas reales mediante valores numéricos; la dificultad para realizar un análisis teórico de la red debido a la presencia de componentes no lineales y a la alta conectividad.

**Figura 4.6:** Arquitectura del PERCEPTRON multicapa.



**Fuente:** Elaboración Propia.

### 4.2.1. Arquitectura del perceptrón multicapa

La arquitectura del PERCETRON multicapa se caracteriza porque tiene sus neuronas agrupadas en capas de diferentes niveles (Referencia [12]). Cada una de las capas está formada por un conjunto de neuronas y se distinguen tres tipos de capas diferentes: la capa de entrada, las capas ocultas y la capa de salida, como se observa en la figura 4.6.

Las neuronas de la capa de entrada no actúan como neuronas propiamente dichas, sino que se encargan únicamente de recibir las señales o patrones que proceden del exterior y propagar dichas señales a todas las neuronas de la siguiente capa. La última capa actúa como la salida de la red, proporcionando al exterior la respuesta de la red para cada uno de los patrones de entrada. Las neuronas de las capas ocultas realizan un procesamiento no lineal de los patrones recibidos.

Como se observa en la figura 4.6, las conexiones del PERCEPTRON multicapa siempre están dirigidas hacia adelante, es decir, las neuronas de una capa se conectan con las neuronas de la siguiente capa, de ahí que reciban también el nombre de redes alimentadas hacia adelante o redes «feedforward». Las conexiones entre las neuronas llevan asociado un número real, llamado peso de la conexión. Todas las neuronas

de la red llevan también asociado un umbral, que en el caso del PERCEPTRON multicapa suele tratarse como una conexión más a la neurona, cuya entrada es constante e igual a 1.

Generalmente, todas las neuronas de una capa están conectadas a todas las neuronas de la siguiente capa. De este modo, las neuronas de la capa de entrada están conectadas a todas las neuronas de la primera capa oculta; las neuronas de la primera capa oculta se conectan a las neuronas de la siguiente capa, etc. Se dice entonces que existe conectividad total o que la red está totalmente conectada.

Aunque en la mayor parte de los casos la arquitectura del PERCEPTRON multicapa está asociada al esquema de la figura 4.6, es posible también englobar dentro de este tipo de redes a arquitecturas con las siguientes características:

- Redes con conexiones de todas o ciertas neuronas de una determinada capa a neuronas de capas posteriores, aunque no inmediatamente posteriores.
- Redes en las que ciertas neuronas de ciertas capas no están conectadas a neuronas de la siguiente capa, es decir el peso de la conexión es constante e igual a cero.

Cuando se aborda un problema con el PERCEPTRON multicapa, en la mayoría de los casos se parte de una arquitectura totalmente conectada, es decir, todas las neuronas de una capa están conectadas a todas las neuronas de la siguiente capa. No es posible demostrar que si se utilizan arquitecturas en las que se eliminan conexiones o se añaden conexiones de una capa a capas no inmediatamente posteriores, se puedan obtener mejores resultados. Sin embargo, en ocasiones, y debido fundamentalmente a la naturaleza del problema, se pueden encontrar redes multicapa con estas características en sus conexiones (Referencia [8]).

#### **4.2.1.1. Propagación de los patrones de entrada**

El PERCEPTRON multicapa define una relación entre las variables de entrada y las variables de salida de la red. Esta relación se obtiene propagando hacia

adelante los valores de las variables de entrada. Para ello, cada neurona de la red procesa la información recibida por sus entradas y produce una respuesta o activación que se propaga, a través de las conexiones correspondientes, hacia las neuronas de la siguiente capa. A continuación, se muestran las expresiones para calcular las activaciones de las neuronas de la red (Referencia [8]).

Sea un PERCEPTRON multicapa con  $C$  capas ( $C - 2$  capas ocultas) y  $n_q$  neuronas en la capa  $q$ , para  $q = 1, 2, \dots, C$ . Sea  $W^q = (w_{ij}^q)$  la matriz de pesos asociada a las conexiones de la capa  $q$  a la capa  $q + 1$  para  $q = 1, 2, \dots, C - 1$ , donde  $w_{ij}^q$  representa el peso de la conexión de la neurona  $i$  de la capa  $c$  a la neurona  $j$  de la capa  $q + 1$ ; y sea  $U^q = (u_i^q)$  el vector de umbrales de las neuronas de la capa  $q$  para  $q = 2, \dots, C$ . Se denota  $a_i^q$  a la activación de la neurona  $i$  de la capa  $q$ ; estas activaciones se calculan del siguiente modo:

- Activación de las neuronas de la capa de entrada  $a_i^1$ . Las neuronas de la capa de entrada se encargan de transmitir hacia la red las señales recibidas del exterior. Por tanto:

$$a_i^1 = x_i \text{ para } i = 1, 2, \dots, n_1 \quad (4.1)$$

donde  $X = (x_1, x_1, \dots, x_{n_1})$  representa el vector o patrón de entrada a la red.


- Activación de las neuronas de la capa oculta  $q$  ( $a_i^q$ ). Las neuronas ocultas de la red procesan la información recibida aplicando la función de activación  $f$  a la suma de los productos de las activaciones que recibe por sus correspondientes pesos, es decir:

$$a_i^q = f\left(\sum_{j=1}^{n_{q-1}} a_j^{q-1} + u_i^q\right) \text{ para } i = 1, 2, \dots, n_q \text{ y } q = 2, 3, \dots, C - 1 \quad (4.2)$$

donde  $a_j^{q-1}$  son las activaciones de las neuronas de la capa  $q - 1$ .

- Activación de las neuronas de la capa de salida ( $a_i^C$ ). Al igual que en el caso anterior, la activación de estas neuronas viene dada por la función de activación  $f$  aplicada a la suma de los productos de las entradas que recibe por sus

**Figura 4.7:** Funciones de activación del PERCEPTRON multicapa.



**Fuente:** Elaboración Propia.

correspondientes pesos:

$$y_i = a_i^C = f\left(\sum_{j=1}^{n_{C-1}} w_{ji}^{C-1} a_j^{C-1} + u_i^C\right) \text{ para } i = 1, 2, \dots, n_C \quad (4.3)$$

donde  $Y = (y_1, y_2, \dots, y_{n_C})$  es el vector de salida de la red.

La función  $f$  es la llamada función de activación. Para el PERCEPTRON multicapa, las funciones de activación más utilizadas son las funciones sigmoideal y la tangente hiperbólica. Dichas funciones poseen como imagen un rango continuo de valores dentro de los intervalos  $[0, 1]$  y  $[-1, 1]$ , respectivamente, y vienen dadas por las siguientes expresiones:

- Función sigmoideal:

$$f_1(x) = \frac{1}{1 + e^{-x}} \quad (4.4)$$

- Función tangente hiperbólica:

$$f_2(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (4.5)$$

Ambas son funciones crecientes con dos niveles de saturación: el máximo, que proporciona salida 1, y el mínimo, salida 0 para la función sigmoideal y salida -1 para la tangente hiperbólica, como se observa en la figura 4.7.

Generalmente, la función de activación en el PERCEPTRON multicapa es común a todas las neuronas de red y es elegida por el diseñador, elección que se realiza

únicamente basándose en los valores de activación que se desee que alcancen las neuronas. Ambas funciones están relacionadas mediante la expresión  $f_2(x) = 2f_1(x) - 1$ , por lo que la utilización de una u otra se elige únicamente en función del recorrido que interese.

En ocasiones, y dependiendo de la naturaleza del problema, las neuronas de salidas se distinguen del resto de neuronas de la red, utilizando otro tipo de función de activación. En este caso, las más usadas son la función identidad y la función escalón.

#### **4.2.1.2. Diseño de la arquitectura del perceptron multicapa**

Cuando se aborda un problema utilizando el perceptron multicapa, uno de los primeros pasos a realizar es el diseño de la arquitectura de la red. Este diseño implica la determinación de la función de activación a emplear, el número de neuronas y el número de capas en la red (Referencia [17]).

Como se ha comentado anteriormente, la elección de la función de activación se suele hacer basándose en el recorrido deseado, y el hecho de elegir una u otra, generalmente, no influye en la capacidad de la red para resolver el problema.

En lo que respecta al número de neuronas y capas, algunos de estos parámetros vienen dados por el problema y otros deben ser elegidos por el diseñador (Referencia [12]).

El número de capas ocultas y el número de neuronas en estas capas deben ser elegidos por el diseñador. No existe un método o regla que determine el número óptimo de neuronas ocultas para resolver un problema dado. En la mayor parte de las aplicaciones prácticas, estos parámetros se determinan por prueba y error. Partiendo de una arquitectura ya entrenada, se realizan cambios aumentando y disminuyendo el número de neuronas ocultas y el número de capas hasta conseguir una arquitectura adecuada para el problema a resolver, que pudiera no ser la óptima, pero que proporciona una solución (Referencia [8]).

### 4.2.2. Algoritmo de RetroPropagación

La regla o algoritmo de aprendizaje es el mecanismo mediante el cual se van adaptando y modificando todos los parámetros de la red (Referencia [12]). En el caso de PERCEPTRON multicapa se trata de un algoritmo de aprendizaje supervisado; es decir, la modificación de los parámetros se realiza para que la salida de la red sea lo más próxima posible a la salida proporcionada por el supervisor o salida deseada. Por tanto, para cada patrón de entrada a la red es necesario disponer de un patrón de salida deseada (Referencia [8]).

Puesto que el objetivo es que la salida de la red sea lo más próxima posible a la salida deseada, el aprendizaje de la red se formula como un problema de minimización de acuerdo a la expresión 4.6 como:

$$\text{Min}_W E \quad (4.6)$$

siendo  $W$  el conjunto de parámetros de la red (pesos y umbrales) y  $E$  una función error que evalúa la diferencia entre las salidas de la red y las salidas deseadas. En la mayor parte de los casos, la función error se define por la ecuación 4.7 como:

$$E = \frac{1}{N} \sum_{i=1}^N e(n) \quad (4.7)$$

donde  $N$  es el número de patrones o muestras y  $e(n)$  es el error cometido por la red para el patrón  $n$ , dado por la ecuación 4.8 como:

$$e(n) = \frac{1}{2} \sum_{i=1}^{n_c} (s_i(n) - y_i(n))^2 \quad (4.8)$$

siendo  $Y(n) = (y_1(n), \dots, y_{n_c}(n))$  y  $S(n) = (s_1(n), \dots, s_{n_c}(n))$  los vectores de salida de la red y salidas para el patrón  $n$ , respectivamente.

De este modo, si  $W$  es un mínimo de la función error  $E$ , en dicho punto el error es próximo a cero, lo cual implica que la salida de la red es próxima a la salida deseada, alcanzando así la meta de la regla de aprendizaje.

Por tanto, el aprendizaje del PERCEPTRON multicapa es equivalente a encontrar un mínimo de la función error. La presencia de funciones de activación no

lineales hace que la respuesta de la red sea no lineal respecto a los parámetros ajustables, por lo que el problema de minimización es un problema no lineal, y, como consecuencia, tienen que utilizarse técnicas de optimización no lineales para su resolución. Dichas técnicas están, generalmente, basadas en una adaptación de los parámetros siguiendo una cierta dirección de búsqueda. En el contexto de redes de neuronas, y en particular para el PERCETRON multicapa, la dirección de búsqueda más comúnmente usada es la dirección negativa del gradiente de la función  $E$  (método de descenso del gradiente), pues conforme al cálculo de varias variables, ésta es la dirección en que la función decrece.

Aunque, estrictamente hablando, el aprendizaje de la red debe realizarse para minimizar el error total (ecuación 4.7), el procedimiento más utilizado está basado en métodos del gradiente estocástico, los cuales consisten en una sucesiva minimización de los errores para cada patrón,  $e(n)$ , en lugar de minimizar el error total  $E$ . Por tanto, aplicando el método del descenso del gradiente estocástico, cada parámetro  $w$  de la red se modifica para cada patrón de entrada  $n$  de acuerdo con la ley de aprendizaje representada por la ecuación 4.9 como:

$$w(n) = w(n - 1) - \alpha \frac{\partial e(n)}{\partial w} \quad (4.9)$$

donde  $e(n)$  es el error para el patrón  $n$  dado por la ecuación 4.8 y  $\alpha$  es la razón o tasa de aprendizaje, parámetro que influye en la magnitud del desplazamiento en la superficie del error.

Debido a que las neuronas de la red están agrupadas en capas de distintos niveles, es posible aplicar el método del gradiente de forma eficiente, resultando el conocido algoritmo de RETROPROPAGACIÓN o regla delta generalizada. El término de retropropagación se utiliza debido a la forma de implementar el método del gradiente en el perceptrón multicapa, pues el error cometido en la salida de la red es propagado hacia atrás, transformándolo en un error para cada una de las neuronas ocultas de la red (Referencia [17]).

#### 4.2.2.1. Obtención de la regla delta generalizada

A continuación se va a desarrollar la regla delta generalizada para el aprendizaje del PERCEPTRON multicapa, que, como ya se ha comentado, no es más que una forma eficiente de aplicar el método del gradiente a los parámetros (pesos y umbrales) de dicha arquitectura [17]. Para el desarrollo de esta regla es necesario distinguir dos casos: uno para los pesos de la capa oculta  $C - 1$  a la capa de salida y para los umbrales de las neuronas de salida, y otro para el resto de los pesos y umbrales de la red, pues las reglas de modificación de estos parámetros son diferentes (Referencia [8]).

**Pesos de la capa oculta  $C - 1$  a la capa de salida y umbrales de la capa de salida.**

Sea  $w_{ji}^{C-1}$  el peso de la conexión de la neurona  $j$  de la capa  $C - 1$  a la neurona  $i$  de la capa de salida. Utilizando el método de descenso del gradiente (ecuación 4.9), dicho parámetro se modifica siguiendo la dirección negativa del gradiente del error:

$$w_{ji}^{C-1}(n) = w_{ji}^{C-1}(n - 1) - \alpha \frac{\partial e(n)}{\partial w_{ji}^{C-1}} \quad (4.10)$$

Por tanto, para la actualización de dicho parámetro es necesario evaluar la derivada del error  $e(n)$  en dicho punto. De acuerdo con la expresión del error (ecuación 4.8) y teniendo en cuenta, por un lado, que las salidas deseadas  $s_i(n)$  para la red son constantes que no dependen del peso y, por otro lado, que el peso  $w_{ji}^{C-1}$  sólo afecta a la neurona de salida  $i$ ,  $y_i(n)$  (ver ecuación 4.3), se obtiene que:

$$\frac{\partial e(n)}{\partial w_{ji}^{C-1}} = -(s_i(n) - y_i(n)) \frac{\partial y_i(n)}{\partial w_{ji}^{C-1}} \quad (4.11)$$

A este punto hay que calcular la derivada de la neurona de salida  $y_i(n)$  respecto al peso  $w_{ji}^{C-1}$ . La salida de la red es la función de activación  $f$  aplicada a la suma de todas las entradas por sus pesos, como se muestra en la ecuación 4.3. Aplicando la regla de la cadena para derivar la composición de dos funciones y teniendo en cuenta que, de todos los términos del sumatorio (ecuación 4.3), el único en el que interviene el peso  $w_{ji}^{C-1}$  es  $w_{ji}^{C-1} a_j^{C-1}$ , y, por tanto, el único cuya derivada es distinta

de cero, se obtiene:

$$\frac{\partial y_i(n)}{\partial w_{ji}^{C-1}} = f' \left( \sum_{j=1}^{n_C} w_{ji}^{C-1} a_j^{C-1} + u_i^C \right) a_j^{C-1}(n) \quad (4.12)$$

Se define el término  $\delta$  asociado a la neurona  $i$  de la capa de salida (capa  $C$ ) y el patrón  $n$ ,  $\delta_i^C(n)$ , del siguiente modo:

$$\delta_i^C(n) = -(s_i(n) - y_i(n)) f' \left( \sum_{j=1}^{n_{C-1}} w_{ji}^{C-1} a_j^{C-1} + u_i^C \right) \quad (4.13)$$

Reemplazando entonces en la ecuación 4.11 el valor de la derivada de la neurona de salida  $y_i(n)$  dado por 4.12 y de acuerdo con el valor  $\delta_i^C(n)$  definido anteriormente (ecuación 4.13), se obtiene que:

$$\frac{\partial e(n)}{\partial w_{ji}^{C-1}} = \delta_i^C(n) a_j^{C-1}(n) \quad (4.14)$$

Finalmente, reemplazando la derivada del error  $e(n)$  respecto al peso  $w_{ji}^{C-1}$  obtenida en 4.14 en la ecuación 4.10, se obtiene la ley para modificar dicho peso, la cual toma la siguiente expresión:

$$w_{ji}^{C-1}(n) = w_{ji}^{C-1}(n-1) + \alpha \delta_i^C(n) a_j^{C-1}(n) \quad (4.15)$$

$$\text{para } j = 1, 2, \dots, n_{C-1}, \quad i = 1, 2, \dots, n_C$$

En la ecuación 4.15 obtenida anteriormente se observa que para modificar el peso de la conexión de la neurona  $j$  de la capa  $C-1$  a la neurona  $i$  de la capa de salida, basta considerar la activación de la neurona de la que parte la conexión (neurona  $j$  de la capa  $C-1$ ) y el término  $\delta$  de la neurona a la que llega la conexión (neurona de salida  $i$ ), término que contiene el error cometido por la red para dicha neurona de salida (ver ecuación 4.13).

La ley de aprendizaje obtenida anteriormente para modificar los pesos de la última capa puede generalizarse para los umbrales de las neuronas de salida. Como se ha comentado en la sección anterior, en el PERCEPTRON multicapa el umbral de una neurona se trata como una conexión más a la neurona cuya entrada es constante e igual a 1. Siguiendo, entonces, la ley anterior (ecuación 4.15), se deduce

que los umbrales de las neuronas de la capa de salida se modifican de acuerdo con la siguiente expresión:

$$u_i^C(n) = u_i^C(n-1) + \alpha \delta_i^C(n) \text{ para } i = 1, 2, \dots, n_C \quad (4.16)$$

**Pesos de la capa  $c$  a la capa  $c+1$  y umbrales de las neuronas de la capa  $c+1$  para  $c = 1, 2, \dots, C-2$ .**

Con el objetivo de que el desarrollo de la regla de aprendizaje para el resto de los pesos y umbrales sea lo más claro posible, se elige un peso de la capa  $C-2$  a la capa  $C-1$ . Sea  $w_{kj}^{C-2}$  el peso de la conexión de la neurona  $k$  de la capa  $C-2$  a la neurona  $j$  de la capa  $C-1$ . Siguiendo el método de descenso del gradiente, la ley para actualizar dicho peso viene dada por:

$$w_{kj}^{C-2}(n) = w_{kj}^{C-2}(n-1) + \alpha \frac{\partial e(n)}{\partial w_{kj}^{C-2}} \quad (4.17)$$

En este caso, y a diferencia del anterior (pesos hacia la capa de salida), el peso  $w_{kj}^{C-2}$  influye en todas las salidas de la red, por que la derivada del error  $e(n)$  (ecuación 4.8) respecto de dicho peso viene dada por la suma de las derivadas para cada una de las salidas de la red, es decir:

$$\frac{\partial e(n)}{\partial w_{kj}^{C-2}} = - \sum_{i=1}^{n_C} (s_i(n) - y_i(n)) \frac{\partial y_i(n)}{\partial w_{kj}^{C-2}} \quad (4.18)$$

Para calcular la derivada de la salida  $y_i(n)$  respecto al peso  $w_{kj}^{C-2}$  es necesario tener en cuenta que este peso influye en la activación de la neurona  $j$  de la capa oculta  $C-1$ ,  $a_j^{C-1}$ , y que el resto de las activaciones de las neuronas en esta capa no dependen de dicho peso. Por tanto, se tiene que:

$$\frac{\partial y_i(n)}{\partial w_{kj}^{C-2}} = f' \left( \sum_{j=1}^{n_{C-1}} w_{ji}^{C-1} a_j^{C-1} + u_i^C \right) w_{ji}^{C-1} \frac{\partial a_j^{C-1}}{\partial w_{kj}^{C-2}} \quad (4.19)$$

Sustituyendo este valor en la ecuación 4.18 y de acuerdo con la definición de  $\delta$  en el punto anterior (ecuación 4.13), se obtiene que:

$$\frac{\partial e(n)}{\partial w_{kj}^{C-2}} = \sum_{i=1}^{n_C} \delta_i^C(n) w_{ji}^{C-1} \frac{\partial a_j^{C-1}}{\partial w_{kj}^{C-2}} \quad (4.20)$$

Para obtener la ley de aprendizaje para el peso  $w_{kj}^{C-2}$ , solo falta derivar la activación de la neurona  $j$  de la capa oculta  $C - 1$ ,  $a_j^{C-1}$ , respecto a dicho peso. De nuevo, aplicando la regla de la cadena a la ecuación 4.2, dicha derivada es:

$$\frac{\partial a_j^{C-1}}{\partial w_{kj}^{C-2}} = f' \left( \sum_{k=1}^{n_{C-2}} w_{kj}^{C-2} a_k^{C-2} + u_j^{C-1} \right) a_k^{C-2}(n) \quad (4.21)$$

Se define el valor  $\delta$  para las neuronas de la capa  $C - 1$ ,  $\delta_j^{C-1}(n)$ , como:

$$\delta_j^{C-1}(n) = f' \left( \sum_{k=1}^{n_{C-2}} w_{kj}^{C-2} a_k^{C-2} + u_j^{C-1} \right) \sum_{i=1}^{n_C} \delta_i^C(n) w_{ji}^{C-1} \quad (4.22)$$

Sustituyendo 4.21 en la ecuación 4.20 y de acuerdo con el valor  $\delta_j^{C-1}(n)$  definido anteriormente, se obtiene que:

$$\frac{\partial e(n)}{\partial w_{kj}^{C-2}} = \delta_j^{C-1}(n) a_k^{C-2}(n) \quad (4.23)$$

Y como consecuencia, la ley de aprendizaje para modificar el peso  $w_{kj}^{C-2}$  viene dada por:

$$w_{kj}^{C-2}(n) = w_{kj}^{C-2}(n-1) + \alpha \delta_j^{C-1}(n) a_k^{C-2}(n) \quad (4.24)$$

para  $k = 1, 2, \dots, n_{C-2}$  y  $j = 1, 2, \dots, n_{C-1}$

Al igual que la ley obtenida para modificar los pesos de la última capa (ecuación 4.15), en este caso, también se observa que para modificar el peso de la conexión de la neurona  $k$  de la capa  $C - 2$  a la neurona  $j$  de la capa  $C - 1$ , basta considerar la activación de la neurona de la que parte la conexión (neurona  $k$  de la capa  $C - 2$ ) y el término  $\delta$  de la neurona a la que llega a la que llega la conexión (neurona  $j$  de la capa  $C - 1$ ) (ver ecuación 4.24). La diferencia radica en la expresión del término  $\delta$ . Para los pesos de la capa  $C - 2$  a  $C - 1$  dicho viene dado por la derivada de la función de activación y por la suma de los términos  $\delta$  asociados a las neuronas de la siguiente capa (en este caso), las neuronas de salida por los pesos correspondientes, como se indica en la ecuación 4.22.

A este punto es posible generalizar fácilmente la ley dada por la ecuación 4.24 para los pesos de la capa  $c$  a la capa  $c + 1$  ( $c = 1, 2, \dots, C - 2$ ). Para ello, basta tener en cuenta la activación de la que parte la conexión y el término  $\delta$  de la neurona a

la que llega la conexión. Este término se calcula utilizando la derivada de la función de activación y la suma de los términos  $\delta$  de las neuronas de la siguiente capa. De este modo:

$$w_{kj}^c(n) = w_{kj}^c(n-1) + \alpha \delta_j^{c+1}(n) a_k^c(n) \quad (4.25)$$

$$\text{para } k = 1, 2, \dots, n_c, \quad j = 1, 2, \dots, n_{c+1} \quad \text{y } c = 1, 2, \dots, C-2$$

donde  $a_k^c(n)$  es la activación de la neurona  $k$  de la capa  $c$  para el patrón  $n$  y  $\delta_j^{c+1}(n)$  viene dado por la siguiente expresión:

$$\delta_j^{c+1}(n) = f' \left( \sum_{k=1}^{n_c} w_{kj}^c a_k^c + u_j^c \right) \sum_{i=1}^{n_{c+1}} \delta_i^{c+2}(n) w_{ji}^c \quad (4.26)$$

Es posible, también, generalizar la ley de aprendizaje para el resto de los umbrales de la red; basta tratarlos como conexiones cuya entrada es constante e iguala 1. La ley para modificarlos viene dada por:

$$u_j^{c+1}(n) = u_j^{c+1}(n-1) + \alpha \delta_j^{c+1}(n) \quad (4.27)$$

$$\text{para } j = 1, 2, \dots, n_{c+1} \quad \text{y } c = 1, 2, \dots, C-2$$

### **Derivada de la función de activación.**

El cálculo de los valores  $\delta$  (ecuaciones 4.13 y 4.26) para cada neurona del PERCEPTRON multicapa requiere el cálculo de la derivada de la función de activación. Como se ha comentado, el PERCEPTRON multicapa puede utilizar dos tipos de funciones de activación, la función sigmoideal (ecuación 4.4) y la función tangente hiperbólica (ecuación 4.5), por lo que los valores  $\delta$  dependen, en principio, de la función de activación empleada. A continuación, se van a obtener las derivadas para ambas funciones de activación, quedando así completado el cálculo de los valores  $\delta$ .

- Derivada de la función sigmoideal

Derivando la expresión dada por la ecuación 4.4, se obtiene que:

$$f_1'(x) = \frac{1}{(1+e^{-x})^2} (-e^{-x}) = \frac{1}{1+e^{-x}} \frac{e^{-x}}{1+e^{-x}} \quad (4.28)$$

Por tanto,

$$f_1'(x) = f_1(x)(1 - f_1(x)) \quad (4.29)$$

Como consecuencia, cuando se utiliza la función sigmoïdal, los valores  $\delta$  asociados a las neuronas de salida (ecuación 4.13) adoptan la siguiente forma:

$$\delta_i^C(n) = -(s_i(n) - y_i(n))y_i(n)(1 - y_i(n)) \text{ para } i = 1, 2, \dots, n_C \quad (4.30)$$

Y los valores  $\delta$  para el resto de las neuronas de la red (ecuación 4.26), vienen dados por:

$$\delta_i^{c+1}(n) = a_j^c(n)(1 - a_j^c(n)) \sum_{i=1}^{n_{c+1}} \delta_i^{c+2}(n)w_{ji}^c \quad (4.31)$$

para  $i = 1, 2, \dots, n_{c+1}$  y  $c = 1, 2, \dots, C - 2$

- Derivada de la función tangente hiperbólica

Teniendo en cuenta que  $f_2(x) = 2f_1(x) - 1$ , la derivada de la función  $f_2(x)$  es:

$$f_2'(x) = 2f_1(x)(1 - f_1(x)) \quad (4.32)$$

Cuando se utilice, por tanto, la función de activación tangente hiperbólica, los valores  $\delta$  para las neuronas de la red adoptan las expresiones dadas por las ecuaciones 4.30 y 4.31 multiplicadas por un factor de 2.

#### 4.2.2.2. Razón de aprendizaje. Inclusión del momento en la ley de aprendizaje.

El cambio en un peso de la red es proporcional al gradiente del error como se refleja en la ecuación 4.9. Dicha proporcionalidad viene dada por el parámetro  $\alpha$ , también llamado razón o tasa de aprendizaje. Este parámetro es el encargado de controlar cuánto se desplazan los pesos de la red en la superficie del error siguiendo la dirección negativa del gradiente. Determina por tanto, la magnitud de dicho desplazamiento, influyendo así en la velocidad de convergencia del algoritmo.

Valores altos de la razón de aprendizaje, en principio, podrían favorecer una convergencia más rápida, pues permiten avanzar rápidamente en la superficie del error. Sin embargo, razones de aprendizaje altas pueden tener consecuencias negativas en el aprendizaje, como que el método se salte un mínimo o incluso que el método oscile alrededor del mínimo. Valores pequeños de razones de aprendizaje podrían evitar

estos problemas, aunque a costa de una convergencia más lenta del algoritmo de aprendizaje, pues la magnitud de los desplazamientos en la superficie del error es más pequeña (Referencia [17]).

Un método simple para evitar inestabilidad en el algoritmo de aprendizaje debido a la razón de aprendizaje es modificar la ley de aprendizaje dada por la Ecuación (3.10) mediante la inclusión de un segundo término, llamado momento, obteniendo así la siguiente ley:

$$w(n) = w(n-1) - \alpha \frac{\partial e(n)}{\partial w} + \eta \Delta w(n-1) \quad (4.33)$$

donde  $\Delta w(n-1) = w(n-1) - w(n-2)$  es el incremento que sufrió el parámetro  $w$  en la iteración anterior y  $\eta$  es un número positivo que controla la importancia asignada al incremento anterior.

Dicha regla fue propuesta por Rumelhart y conserva las propiedades de la regla anterior (ecuación 4.9) en el sentido de que modifica los parámetros de la red con el objetivo de minimizar la función error  $E$  (ecuación 4.7). Sin embargo, el nuevo término,  $\eta \Delta w(n-1)$ , incorpora en el método cierta inercia, haciendo que la modificación actual del parámetro dependa de la dirección de la modificación anterior, lo cual puede evitar oscilaciones.

Aplicando sucesivamente la ecuación 4.33 al término  $\Delta w(n-1)$ , se obtiene que:

$$\begin{aligned} \Delta w(n-1) &= w(n-1) - w(n-2) = -\alpha \frac{\partial e(n-1)}{\partial w} + \eta \Delta w(n-2) = \\ &= \dots = -\alpha \sum_{t=0}^{n-1} \eta^{n-1-t} \frac{\partial e(t)}{\partial w} \end{aligned}$$

Por tanto, la ley dada por la ecuación 4.33 puede escribirse de la forma:

$$w(n) = w(n-1) - \alpha \sum_{t=0}^n \eta^{n-t} \frac{\partial e(t)}{\partial w} \quad (4.34)$$

En la expresión obtenida anteriormente se observa que el cambio actual de un parámetro viene dado por la suma de los gradientes del error para todas las iteraciones anteriores. Por tanto, cuando la derivada parcial del error respecto al peso tiene signos opuestos en iteraciones consecutivas, la suma puede contrarrestar estos cambios de signos, y, de este modo, procurar un cambio más suave en el peso, los

cual conduce a un método más estable, sin oscilaciones bruscas. Por otra parte, si la derivada parcial del error respecto al peso tiene el mismo signo en iteraciones consecutivas, la utilización del momento procura un cambio mayor en el peso, acelerando así la convergencia del algoritmo (Referencia [8]).

### 4.2.3. Proceso de aprendizaje del Perceptron multicapa.

Como se ha comentado anteriormente, el objetivo del aprendizaje o entrenamiento del PERCEPTRON multicapa es ajustar los parámetros de la red (pesos y umbrales) con el fin de que las entradas presentadas produzcan las salidas deseadas, es decir, con el fin de minimizar la función error  $E$  (ecuación 4.7). En esta sección, se van a detallar los pasos que involucra el proceso completo de aprendizaje del PERCEPTRON multicapa (Referencia [8]).

Sea  $\{(X(n), S(n)), n = 1, \dots, N\}$  el conjunto de muestras o patrones que representan el problema a resolver, donde  $X(n) = (x_1(n), \dots, x_{n_1}(n))$  son los patrones de entrada a la red,  $S(n) = (s_1(n), \dots, s_{n_c}(n))$  son las salidas deseadas para dichas entradas y  $N$  es el número de patrones disponibles. Generalmente, es frecuente encontrar los patrones de entrada y salida normalizados o escalados mediante una transformación lineal en los intervalos  $[0, 1]$  o  $[-1, 1]$  dependiendo de la función de activación empleada, sigmoideal o tangente hiperbólica, respectivamente. Es necesario señalar, sin embargo, que esta transformación de los patrones no es una condición necesaria para realizar el aprendizaje de la red, sino que los datos pueden presentarse a la red sin sufrir dicha normalización. Sólo será necesario tener en cuenta que, en el caso de que los patrones de salida se utilicen sin escalar, la función de activación de las neuronas de salida de la red debe ser la identidad, pues si se utilizan funciones de activación sigmoideas, las salidas de la red siempre estarán en los rangos de valores  $[0, 1]$  o  $[-1, 1]$  y, por tanto, nunca podrán aproximarse a la salida deseada.

Los pasos que componen el proceso de aprendizaje del PERCEPTRON multicapa son los siguientes:

1. Se inicializan los pesos y umbrales de la red. Generalmente, esta inicialización

- es aleatoria y con valores alrededor del cero.
2. Se toma un patrón  $n$  del conjunto de entrenamiento,  $(X(n), S(n))$ , y se propaga hacia la salida de la red el vector de entrada  $X(n)$  utilizando las ecuaciones 4.1, 4.2 y 4.3, obteniéndose así la respuesta de la red para dicho vector de entrada,  $Y(n)$ .
  3. Se evalúa el error cuadrático cometido por la red para el patrón  $n$  utilizando la ecuación 4.8.
  4. Se aplica la regla delta generalizada para modificar los pesos y umbrales de la red. Para ello se siguen los siguientes pasos:
    - a) Se calculan los valores  $\delta$  para todas las neuronas de la capa de salida utilizando la ecuación 4.13.
    - b) Se calculan los valores  $\delta$  para el resto de las neuronas de la red utilizando la ecuación 4.26 empezando desde la última capa oculta y retropropagando dichos valores hacia la capa de entrada.
    - c) Se modifican pesos y umbrales de la red siguiendo las ecuaciones 4.15 y 4.16 para los pesos y umbrales de la capa de salida y 4.25 y 4.27 para el resto de los parámetros de la red.
  5. Se repiten los pasos 2, 3 y 4 para todos los patrones de entrenamiento, completando así una iteración o ciclo de aprendizaje.
  6. Se evalúa el error total  $E$  (ecuación 4.7) cometido por la red. Dicho error también recibe el nombre de error de entrenamiento, pues se calcula utilizando los patrones de entrenamiento.
  7. Se repiten los pasos 2, 3, 4, 5 y 6 hasta alcanzar un mínimo del error de entrenamiento, para lo cual se realizan los  $m$  ciclos de aprendizaje.

#### 4.2.3.1. Capacidad de generalización.

A la hora de evaluar el comportamiento de una red de neuronas, y en particular del PERCEPTRON multicapa, no sólo es importante saber si la red ha aprendido con éxito los patrones utilizados durante el aprendizaje, sino que es imprescindible, también, conocer el comportamiento de la red ante patrones que no se han utilizado durante el entrenamiento. Es decir, de nada sirve disponer de una red que haya aprendido correctamente los patrones de entrenamiento y que no responda adecuadamente ante patrones nuevos. Es necesario que durante el proceso de aprendizaje la red extraiga las características de las muestras, para poder así responder correctamente a patrones diferentes. Esto se conoce como la capacidad de la red para generalizar las características presentes en el conjunto de muestras o capacidad de generalización de la red (Referencia [17]).

Por tanto, cuando se realiza el proceso de aprendizaje de la red es muy importante, e incluso imprescindible, evaluar la capacidad de generalización. Para ello, es necesario disponer de dos conjuntos de muestras o patrones; uno para entrenar la red y modificar sus pesos y umbrales (conjunto de entrenamiento), y otro para medir la capacidad de la red para responder correctamente ante patrones que no han sido utilizados durante el entrenamiento (conjunto de validación o test). Estos conjuntos se obtienen de las muestras disponibles sobre el problema y es conveniente que la separación sea aleatoria, con el fin de tener conjuntos lo más representativos posible, tanto de entrenamiento como de validación (Referencia [8]).

#### 4.2.3.2. Deficiencias del algoritmo de aprendizaje.

A pesar del éxito del algoritmo de RETROPROPAGACIÓN para entrenar el PERCEPTRON multicapa, este algoritmo posee también una serie de deficiencias, las cuales son analizadas a continuación.

- **Mínimos Locales.** La superficie que define el error  $E$  (ecuación 4.7) en función de los parámetros de la red es compleja y llena de valles y colinas. Debido a la utilización del método del gradiente para encontrar un mínimo de esta

función error, se corre el riesgo de que el proceso de minimización finalice en un mínimo local. Se ha mencionado anteriormente que el proceso de adaptar los pesos finaliza cuando  $\frac{\partial E}{\partial w} \approx 0$ , lo cual no garantiza que el mínimo alcanzado sea un mínimo global, sino simplemente que se ha alcanzado un mínimo, que podría ser local. Claramente, es indeseable que el proceso de aprendizaje de la red finalice en un mínimo local, sobre todo si dicho mínimo está localizado lejos del mínimo global (Referencia [8]) .

- **Parálisis.** El fenómeno de la parálisis, también conocido como saturación, en el PERCEPTRON multicapa se produce cuando la entrada total a una neurona de la red toma valores muy altos, tanto positivos como negativos. Debido a que las funciones de activación poseen asíntotas horizontales (ver figura 4.7), si la entrada a una neurona alcanza un valor alto, ésta se satura y alcanza un valor de activación máximo o mínimo (Referencia [8]).

## **Parte III**

### **Materiales y Métodos**

## Capítulo 5

# Medición de la Precipitación global


Este capítulo se basa en la traducción e interpretación de artículos proporcionados por la NASA relacionados a la Misión de Medición de LLuvias Tropicales. Además proporciona información obtenida por investigadores, tesis y páginas web. Cabe mencionar que la mayor parte de la literatura sobre este tema se encuentra en inglés por lo que la información presentada aquí en español ayudará a comprender la Misión de la Medición de LLuvias Tropicales (TRMM).

### 5.1. Misión de la Medición de las Lluvias Tropicales TRMM

La Misión de la Medición de LLuvias Tropicales (TRMM) es una misión conjunta entre la Administración Nacional de la Aeronáutica y del Espacio (NASA) de los Estados Unidos y la Agencia de Exploración Aeroespacial (JAXA) del Japón diseñado para medir precipitaciones y la investigación del clima.

El TRMM es un satélite de investigación (ver figura 5.1) diseñado para mejorar nuestra comprensión de la distribución y variabilidad de la precipitación dentro de los trópicos como parte del ciclo del agua en el sistema climático actual. Al hacer referencia a las regiones tropicales y subtropicales de la Tierra, el TRMM proporciona toda la información necesaria sobre la lluvia y sus liberaciones de calor asociados que ayudan a potenciar la circulación atmosférica global que da forma al tiempo y el

**Figura 5.1:** El Satélite TRMM.



**Fuente:** Página Web del TRMM.

clima. En coordinación con otros satélites en los sistemas de observación de la Tierra de la NASA, el TRMM proporciona información importante de la precipitación usando varios instrumentos espaciales para incrementar nuestra comprensión de las interacciones entre el vapor de agua, nubes y precipitación, que son fundamentales para la regulación del clima de la Tierra.<sup>1</sup>

### **5.1.1. Descripción General de la Misión TRMM**

Uno de los grandes desafíos que enfrenta la humanidad en el siglo XXI es la amenaza del cambio climático global debido al aumento de los niveles de dióxido de carbono y otros gases de efecto invernadero en la atmósfera ¿Es la verdadera amenaza?. Los modelos de computadora que predicen el clima futuro aún difieren en algunos aspectos muy importantes con algunos modelos de predicción de poco o ningún calentamiento, mientras que otros predicen aumentos de temperatura que alterarían sustancialmente nuestra forma de vida. Sin más datos y una mejor

---


<sup>1</sup>Traducido e interpretado de la página web del TRMM (Misión de la medición de las Lluvias Tropicales). Para mayor información visitar la página web del TRMM <http://pmm.nasa.gov/>  
TRMM

comprensión del sistema climático actual, hay pocas esperanzas de que podamos entender las diferencias entre los modelos actuales y ambas partes en el debate medioambiental continuarán presionando por sus puntos de vista.

El balance de energía de la atmósfera global muestra que solamente alrededor de un cuarto de la energía necesaria para conducir la circulación atmosférica global viene directamente de la energía solar. El otro tres cuartos de la energía se transfiere a la atmósfera mediante la evaporación del agua principalmente desde los océanos. Como el vapor de agua se eleva desde la superficie, lleva consigo la energía que se necesita para convertir el agua líquida en vapor de agua «el calor latente de evaporación». La mayor parte de este calor latente es liberada en la atmósfera en grandes cúmulos de nubes ecuatoriales cuando el vapor se condensa para formar nubes y gotas de lluvia. La energía de calor latente contenida en las nubes no puede ser vista o medida directamente. La lluvia, sin embargo, es el producto de la liberación de esta energía, y la precipitación se puede medir. Responsable de las tres cuartas partes de la energía que impulsa la circulación atmosférica global. La lluvia tropical se puede decir que conduce la máquina del clima. Desafortunadamente, aún existen dudas de hasta el 50% en la cantidad de lluvia tropical. A menos que podamos definir mejor la cantidad de lluvia tropical y la energía liberada cuando se produce lluvias, tendremos muy pocas posibilidades de poner a los modelos climáticos a través de la rigurosa prueba que necesitamos para ganar confianza en sus predicciones.

Desde el lanzamiento en 1997, el TRMM ha proporcionado mediciones de precipitación críticas en las regiones tropicales y subtropicales de nuestro planeta. El radar de precipitación (PR) puede ver a través de la columna de precipitación, proporcionando nuevos conocimientos sobre la estructura e intensificación de la tormenta tropical. El TRMM microondas Imager (TMI) obtiene medidas de la energía del microondas emitida por la Tierra y su atmósfera para cuantificar el vapor de agua, el agua de las nubes, y la intensidad de las precipitaciones en la atmósfera. Mediciones de precipitación del TRMM han hecho y continúan proporcionando insumos críticos para la predicción de ciclones tropicales, predicción numérica del tiempo, y climatologías de precipitación, en muchos otros trópicos, así como una amplia gama

**Figura 5.2:** Instrumentos del TRMM.



Fuente: Página Web del TRMM.

de aplicaciones sociales. <sup>2</sup>.

### 5.1.2. Instrumentos del TRMM

La Misión de Medición de Lluvias Tropicales es la primera misión de ciencias de la Tierra dedicado a estudiar la precipitación tropical y subtropical: precipitación que cae dentro de los 35 grados norte y 35 grados al sur del Ecuador. La lluvia tropical comprende más de dos tercios del total del mundo. El satélite utiliza varios instrumentos para detectar las precipitaciones incluyendo el radar, imágenes de microondas y sensores de rayos (ver figura 5.2). Volando a una altitud orbital bajo de 240 millas (400 kilómetros) de recogida de datos del TRMM de precipitación tropical ayuda a mejorar nuestra comprensión sobre el clima y el tiempo.

La agencia espacial japonesa (JAXA) lanzó el satélite en un cohete H-II desde el Centro Espacial Tanegashima, el 27 de noviembre de 1997.

Ahora cruzando en su segunda década de funcionamiento, el TRMM comanda un puesto de honor histórico que la mayoría de otras misiones científicas de la Tierra

---

<sup>2</sup>Traducido e interpretado de la página web del TRMM (Misión de la medición de las Lluvias Tropicales). Para mayor información visitar la página web del TRMM <http://pmm.nasa.gov/TRMM>

**Figura 5.3:** Escáner Visible e Infrarrojo (VIRS).



**Fuente:** Página Web del TRMM.

no pueden reclamar. Desde el principio, este satélite único en su clase y la ciencia que va con ella es únicamente una tarea del Centro de Vuelo Espacial Goddard. La expresión más evidente de esto es su construcción.

Mientras que la mayoría de otras naves de investigación son obra directa de contratistas designados u otras partes externas, ingenieros funcionarios del Centro de Vuelo Espacial Goddard dirigieron la realización y construyeron la nave casi en su totalidad en el local. También completaron la integración de todos los instrumentos científicos a bordo.<sup>3</sup>

#### **5.1.2.1. Escáner Visible e Infrarrojo (VIRS)**

El escáner visible e infrarrojo (VIRS) es uno de los principales instrumentos a bordo del observatorio de la Misión de Medición de Lluvias Tropicales (TRMM). VIRS (ver figura 5.3) es uno de los tres instrumentos en el paquete de medición de la lluvia y sirve como un indicador muy indirecto de las precipitaciones. También concuerdan mediciones TRMM con otras mediciones que se realizan de forma rutinaria utilizando los Satélites Ambientales meteorológicos de órbita polar (POES) y los que se hacen utilizando los satélites geoestacionarios operacionales del medio ambiente (GOES) operados por los Estados Unidos.

VIRS, como su nombre lo indica, detecta la radiación que viene de la Tierra en cinco regiones espectrales, que van desde lo visible hasta el infrarrojo, o 0,63 a

---

<sup>3</sup>Para más información del Centro de Vuelo Espacial Goddard visitar la página web <http://www.nasa.gov/centers/goddard/home>

12 micrómetros. VIRS está incluido en el paquete de instrumentos principales, por dos razones. En primer lugar es su capacidad para delinear las precipitaciones. La segunda y aún más importante razón, es servir como un estándar de transferencia a otras mediciones que se realizan de forma rutinaria usando satélites POES y GOES. La intensidad de la radiación en las diferentes regiones espectrales (o bandas) se puede utilizar para determinar el brillo (visible e infrarrojo cercano) o la temperatura (infrarrojos) de la fuente.

#### **5.1.2.2. TRMM Microondas Generador de Imagen (TMI)**

El TRMM Microondas Generador de Imagen es un sensor de microondas pasivo diseñado para proporcionar información cuantitativa de precipitación sobre una amplia franja bajo el satélite TRMM. Midiendo cuidadosamente las cantidades de energía emitida por la Tierra y su atmósfera, el TMI es capaz de cuantificar el vapor de agua, el agua de las nubes, y la intensidad de la lluvia en la atmósfera. Es un instrumento relativamente pequeño que consume poca energía. Esto, combinado con la amplia franja, hacen la información cuantitativa respecto a las precipitaciones del TMI el «caballo de batalla» del paquete de la Misión de Medición LLuvias Tropicales.

#### **5.1.2.3. El Radar de Precipitación (PR)**

El radar de precipitación fue el primer instrumento del vehículo espacial diseñado para proporcionar mapas tridimensionales de la estructura de la tormenta. Estas medidas dan información muy valiosa sobre la intensidad y la distribución de la lluvia, del tipo lluvia, de la profundidad de la tormenta y de la altura a la que la nieve se derrite en la lluvia. Las estimaciones del calor liberado a la atmósfera a diferentes alturas sobre la base de estas mediciones se pueden utilizar para mejorar los modelos de la circulación atmosférica global.

El radar de precipitación tiene una resolución horizontal en el suelo de alrededor de 3,1 millas (cinco kilómetros) y un ancho de franja de 154 millas (247 kilómetros). Una de sus características más importantes es su capacidad para proporcionar los

perfiles verticales de la lluvia y la nieve de la superficie hasta una altura de cerca de 12 millas (20 kilómetros). El radar de precipitación es capaz de detectar tasas de lluvia bastante ligeras hasta aproximadamente 0,027 pulgadas (0,7 milímetros) por hora. En las tasas de lluvia intensas, en los que los efectos de atenuación pueden ser fuertes, nuevos métodos de procesamiento de datos se han desarrollado para ayudar a corregir este efecto. El radar de precipitación es capaz de separar ecos de lluvia para tamaños de muestras verticales de unos 820 pies (250 metros) cuando se mira hacia abajo. Lleva a cabo todas estas medidas mediante el uso de sólo 224 vatios de potencia de la energía eléctrica de sólo unos pocos bombillas domésticas. El radar de precipitación fue construido por la Agencia Nacional de Desarrollo Espacial (JAXA) de Japón como parte de su contribución a la articulación de la Misión de Medición de Lluvias Tropicales (TRMM) Estados Unidos / Japón.

#### **5.1.2.4. Las Nubes y el Sistema de Energía Radiante de la Tierra (CERES)**

El instrumento de Las Nubes y el Sistema de Energía Radiante de la Tierra (CERES) es uno de los cinco instrumentos que están siendo trasladados a bordo del observatorio de la Misión de Medición de Lluvias Tropicales (TRMM). Los datos del instrumento CERES (ver figura 5.4) fueron usados para estudiar la energía intercambiada entre el Sol; la atmósfera, superficie y nubes de la Tierra; y el espacio. Sin embargo, sólo funcionó durante el periodo de enero hasta agosto de 1998 y marzo del 2000, por lo que el registro de datos disponibles es bastante breve.

#### **5.1.2.5. Sensor de Imágenes de Rayos (LIS)**

El Sensor de Imágenes de Rayos es un instrumento pequeño, altamente sofisticado que detecta y localiza un rayo sobre la región tropical del globo. Mirando hacia abajo desde un punto panorámico a bordo del observatorio de la Misión de Medición de Lluvias Tropicales (TRMM), 250 millas (402 kilómetros) por encima de la Tierra, el sensor proporciona información que podría conducir a un futuro avanzado de sensores de rayos capaces de mejorar significativamente el tiempo «predicción

**Figura 5.4:** Las Nubes y el Sistema de Energía Radiante de la Tierra (CERES).



**Fuente:** Página Web del TRMM.

inmediata».

Usando un punto de observación en el espacio, el sensor de imágenes de relámpagos promete ampliar las capacidades de los científicos para la topografía del rayo y actividad tormentosa en una escala global. Le ayudará a allanar el camino para futuros creadores de mapas de rayos geostacionarios. Desde su posición en la órbita estacionaria, estos sensores de rayos futuros proporcionarían una cobertura continua de los Estados Unidos, océanos cercanos y partes de América Central. Los investigadores esperan que los futuros sensores entregarán día y noche información del relámpago al puesto de trabajo de un pronosticador dentro de los 30 segundos de ocurrencia, proporcionando una herramienta invaluable para la tormenta «predicción inmediata», así como para la emisión de avisos de tormentas severas.

El detector de rayo es una combinación compacta de elementos ópticos y electrónicos, incluyendo una cámara mirando capaz de localizar y detectar relámpagos en las tormentas individuales. El campo del generador de imágenes de vista permite que al sensor observar un punto de la Tierra o una nube durante 80 segundos, un tiempo suficiente para estimar la tasa de parpadear, lo que le dice a los investigadores si una tormenta está creciendo o en descomposición.

### **5.1.3. Características de la órbita del TRMM**

El satélite TRMM (Tropical Rainfall Measuring Mission) provee algunos de los primeros datos detallados y comprensibles del carácter cuadridimensional de la distribución de la lluvia y del calor latente en la vasta región oceánica y continental de régimen tropical. A continuación se presentan algunas características de la órbita del TRMM.

El área geográfica cubierta por el TRMM es la siguiente:

- Latitud: 38° S - 38° N
- Longitud: 180° W - 180° E


El TRMM orbita la tierra alrededor de 16 veces al día. Cada órbita tiene una duración de 92.5 minutos.

La altitud del satélite fue cambiada el 2001 de 350 a 402.5 km para ahorrar combustible y extender su vida útil. A este cambio de altitud se le conoce como el boost, este cambio de altitud ha ampliado el ancho de la franja observada en la superficie por el radar de precipitación del satélite más conocida como swath que pasó de ser 215 km a 245 km, y también la resolución horizontal de la cobertura del haz o footprint cambió de 4.3 km a 5 km (Referencia [6]).

### **5.1.4. La geometría de escaneo del Radar de precipitación PR del TRMM**

El radar de precipitación escanea en la dirección transversal a su dirección de vuelo (ver figura 5.5). Cada escaneo contiene 49 haces denominados rayos, los cuales corresponden a un ángulo fijo de la antena dentro de un sector angular de 34°, para este sector angular se forma en la superficie un swath de 245 km de ancho. El rayo 25 corresponde a la dirección del nadir, los rayos 1 y 49 corresponden al borde del swath, en los bordes del swath cada ángulo de la antena es  $\pm 17^\circ$ . El ancho de cada haz (beamwidth) es de 0.70 y el diámetro del pie de haz es de aproximadamente 5 km sobre el elipsoide de referencia. Para un rayo dado, el satélite comienza a grabar

**Figura 5.5:** Geometría de escaneo actual del radar de precipitación a bordo del satélite TRMM.



Fuente: Página Web del TRMM.

muestras a cierto rango o distancia del satélite, con una resolución de rango de 250 m la cual es igual a la resolución vertical en el nadir. El PR graba muestras para 80 niveles de altura en cada rayo, que van desde la altura del elipsoide de referencia hasta 20 km en el nadir.

Cada pie de haz es de forma circular y tiene coordenadas de latitud y longitud dadas para el punto central del círculo a la altura del elipsoide de referencia. Todos los valores calculados por los productos del PR como la lluvia en la superficie y la altura de la tormenta son georeferenciados respecto del elipsoide de referencia, por ello y debido a la inclinación de los rayos que están a los extremos del swath, si el área de estudio está a una altura diferente del elipsoide de referencia los valores de geolocalización deben ser corregidos tomando la proyección del rayo a dicha altura (Referencia [6]).

### 5.1.5. Descripción general los productos del TRMM

La información registrada por los sensores a bordo del TRMM incluido el radar de precipitación ha sido dispuesta por la NASA Earth Data en tres niveles, los cuales se distinguen por el procesamiento que se le ha hecho a las mediciones. A continuación se dará una breve descripción de los productos del radar de precipitación. Entre los productos del nivel 1 tenemos el producto 1B21 que convierte los conteos del eco registrados por el radar en la potencia de eco de radar y en potencia de ruido. El producto 1C21 calcula el factor de reflectividad del radar a partir de la potencia usando la ecuación del radar. En nivel 2 tenemos el producto 2A21 que calcula la atenuación de camino que luego es usada en el producto 2A25 para calcular la atenuación del factor de reflectividad, así también tenemos el producto 2A23 que clasifica la lluvia por tipos y el producto 2A25 que proporciona, entre otras variables, el factor de reflectividad corregido cerca de la superficie y un estimado de la lluvia en la superficie a una resolución de  $0.04^\circ$ .

Finalmente están los productos del nivel 3, algunos de ellos utilizan una combinación de distintos sensores y de distintos satélites y nos dan las estadísticas de la precipitación mensual a una resolución de  $0.5^\circ$  y  $5^\circ$ . Uno de los productos más usados es el producto 3B42 que provee estimados de precipitación cada 3 horas a una resolución de  $0.25^\circ$ , pero se sabe de estudios previos que las correlaciones entre los estimados de lluvia del 3B42 y los pluviómetros para lluvias diarias tienen valores muy modestos, además se sobreestiman las cantidades de lluvia ligera menores a 2 mm/hr y subestiman las cantidades medianas y grandes de lluvia diaria (Referencia [6]).

# Capítulo 6

## Redes de Neuronas Artificiales (Enfoque MATLAB)

Este capítulo se basa en la traducción e interpretación de la Guía de Usuario de la Caja de Herramientas de Redes Neuronales de MATLAB (Referencia [13]). Considerada a mi parecer como la mejor manera de inicializar en el estudio de Redes Neuronales por su explicación textual y gráfica. MATLAB tiene prácticamente incorporado todo el conocimiento acerca de Redes Neuronales hasta la fecha.

Previamente se adquirió el manejo del software MATLAB de las Referencias [11], [18], [19] entre otros.

### 6.1. Introducción a la Caja de Herramientas de Redes Neuronales de MATLAB

#### 6.1.1. Flujo de Trabajo para Diseño de Redes Neuronales

El flujo de trabajo para el proceso de diseño de la Red Neuronal tiene siete pasos principales:

1. Recopilar Datos.
2. Crear la Red.

3. Configurar la Red.
4. Inicializar los Pesos y Umbrales.
5. Entrenar la Red.
6. Validar la Red.
7. Usar la Red.

La caja de herramientas de Redes Neuronales de MATLAB utiliza el objeto de red para almacenar toda la información que define una Red Neuronal.

Después de que una Red Neuronal ha sido creada, necesita ser configurada y luego entrenada. La configuración implica la organización de la red de modo que sea compatible con el problema que desea resolver, de acuerdo con datos de ejemplo.


Después que la red se ha configurado, los parámetros de la red ajustables (llamados pesos y umbrales) necesitan ser ajustados, de manera que se optimiza el rendimiento de la red. Este proceso de ajuste se conoce como el entrenamiento de la red. La configuración y entrenamiento requieren que la red sea proporcionada con datos de ejemplo.

### **6.1.2. Cuatro Niveles de Diseño de Redes Neuronales**

Hay cuatro diferentes niveles en que la Caja de Herramientas de Redes Neuronales de MATLAB puede ser utilizada. El primer nivel es representado por las Interfaces Gráficas de Usuario. Este proporciona una manera rápida para acceder al potencial de la Caja de Herramientas de Redes Neuronales de MATLAB para muchos problemas de función de ajuste, patrones de reconocimiento, agrupación y análisis de series de tiempo.

El uso del segundo nivel es a través de operaciones básicas en la línea de comandos. Las funciones de la línea de comandos utilizan listas de argumentos sencillos con la configuración predeterminada inteligente para parámetros de función. Las Interfaces Gráficas de Usuario pueden generar automáticamente archivos de código

**Figura 6.1:** Neurona de entrada única.



**Fuente:** Elaboración propia.

MATLAB con la implementación de la línea de comandos de las operaciones de la Interfaz Gráfica de Usuario.

Un tercer nivel de uso de la Caja de Herramientas de Redes Neuronales de MATLAB es la personalización de la caja de herramientas. Esta capacidad avanzada le permite crear sus propias Redes Neuronales personalizadas, sin dejar de tener acceso a todas las funciones de la caja de herramientas.

El cuarto nivel es la posibilidad de modificar cualquiera de los archivos M contenidos en la caja de herramientas. Cada componente computacional está escrito en código MATLAB y es totalmente accesible.

### 6.1.3. Modelo de Neurona

#### 6.1.3.1. Neurona Simple

El bloque de construcción fundamental para las Redes Neuronales es la neurona de entrada única, como en la figura 6.1.

Hay tres operaciones fundamentales distintas que tienen lugar en este ejemplo de neurona. En primer lugar, la entrada escalar  $p$  se multiplica por el peso escalar  $w$  para formar el producto  $wp$ , de nuevo un escalar. En segundo lugar, el ingreso ponderado  $wp$  se añade al umbral escalar  $b$  para formar el ingreso a la red  $n$ . Por último, la entrada a la red pasa a través de la función de transferencia  $f$ , que produce el escalar de salida  $a$ . Los nombres dados a estos tres procesos son: la función de peso, la función de entrada a la red y la función de transferencia.

Tenga en cuenta que  $w$  y  $b$  son ambos parámetros ajustables de la neurona. La

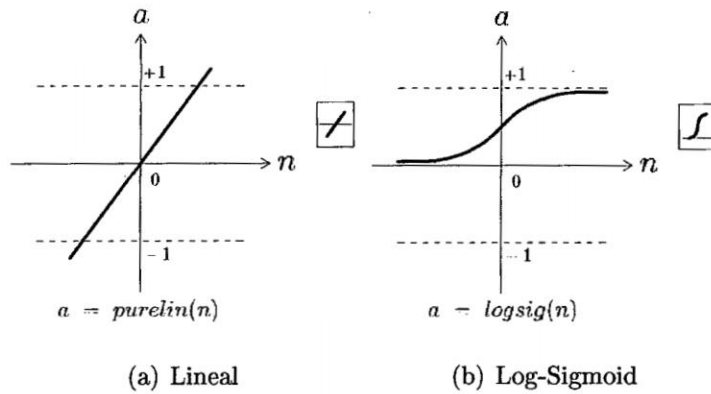
idea de las Redes Neuronales es que tales parámetros se puedan ajustar de manera que la red exhiba un comportamiento deseado o interesante. Por lo tanto, se puede entrenar la red para hacer un trabajo en particular mediante el ajuste de los parámetros de peso o umbral.

Todas las neuronas en la Caja de Herramientas de Redes Neuronales de MATLAB tienen provisión para un umbral; sin embargo, se puede omitir un umbral en una neurona si lo desea.

### 6.1.3.2. Funciones de Transferencia

Muchas funciones de transferencia se incluyen la Caja de Herramientas de Redes Neuronales de MATLAB. Dos de las funciones más comúnmente usadas se muestran en la figura 6.2. En la parte izquierda se ilustra la función de transferencia lineal y en la parte derecha la función de transferencia sigmoideal.

**Figura 6.2:** Funciones de Transferencia.




**Fuente:** Elaboración propia.

El símbolo en la casilla a la derecha de cada gráfico de la función de transferencia que se muestra en la figura 6.2 representa la función de transferencia asociada.

Estos íconos reemplazan el  $f$  general en los bloques del diagrama de red para mostrar la función de transferencia particular que se está usando.

**Figura 6.3:** Neurona de entrada única con vector de ingreso.



Donde  
 $R$  - número de elementos  
 en el vector de ingreso

Fuente: Elaboración propia.

### 6.1.3.3. Neurona con vector de ingreso

La neurona simple puede ser extendida para manejar ingresos que son vectores. Una neurona con un único vector de entrada de  $R$  elementos se muestra en la figura 6.3.

$$p_1, p_2, \dots, p_R$$

se multiplican por los pesos

$$w_{1,1}, w_{1,2}, \dots, w_{1,R}$$

y los valores ponderados se alimentan a la unión sumadora. Su suma es simplemente  $wp$ , el producto escalar de la matriz  $w$  (fila única) y el vector  $p$ .

La neurona tiene un umbral  $b$ , que se suma con las entradas ponderadas para formar la entrada neta  $n$ . La entrada neta  $n$  es el argumento de la función de transferencia  $f$  y se muestra en la ecuación 6.1.

$$n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b \tag{6.1}$$


La ecuación 6.1, por supuesto, puede ser escrita en código MATLAB como la ecuación 6.2

$$n = wp + b \tag{6.2}$$

### 6.1.3.4. Notación abreviada

La figura 6.3 de una sola neurona contiene una gran cantidad de detalles. Si tenemos en cuenta las redes de muchas neuronas, y quizás capas de muchas neuronas,

**Figura 6.4:** Notación abreviada de neurona de entrada única.



**Fuente:** Elaboración propia.

hay tanto detalle que los principales pensamientos tienden a perderse. Por lo tanto, los autores de la Guía de Usuario de la Caja de Herramientas de Redes Neuronales de MATLAB han ideado una notación abreviada para una neurona individual. Esta notación, que se utiliza más adelante en circuitos de múltiples neuronas se muestra en la figura 6.4.

Aquí el vector de ingreso  $p$  está representado por la barra vertical sombreada sólida en la izquierda. Las dimensiones de  $p$  se muestran debajo del símbolo  $p$  en la figura como  $R \times 1$ . Así  $p$  es un vector de  $R$  elementos de ingreso. Tenga en cuenta que si hay más de una neurona, la salida de la red sería un vector.

Una capa de red se define en la figura 6.4. Cada vez que se usa esta notación abreviada de la red, los tamaños de las matrices se muestran justo debajo de sus nombres de las variables de la matriz. Esta notación permitirá entender las arquitecturas y seguir las matemáticas de la matriz asociadas con ellos.

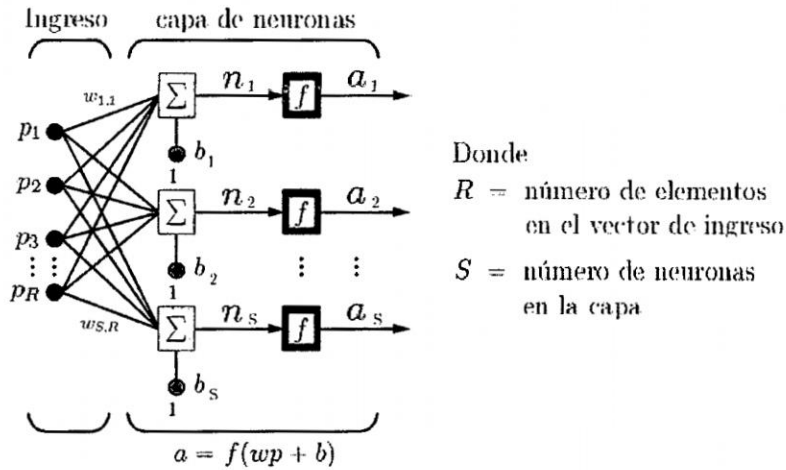
#### 6.1.4. Arquitecturas de la Red Neuronal

Dos o más de las neuronas mostradas en la figura 6.4 pueden ser combinadas en una capa y una red particular podría contener una o más de tales capas.

##### 6.1.4.1. Una Capa de Neuronas

Una red de una sola capa con  $R$  elementos de ingreso y  $S$  neuronas se muestra en la figura 6.5. En esta red, cada elemento del vector de ingreso  $p$  está conectada

**Figura 6.5:** Red de una sola capa con  $R$  elementos de ingreso y  $S$  neuronas.




**Fuente:** Elaboración propia.

a cada neurona de entrada a través de la matriz de peso  $w$ . La neurona  $i$ -ésima tiene una sumadora que recoge las entradas ponderadas y umbrales para formar su propia salida escalar  $n(i)$ . Las diversas  $n(i)$  tomadas en conjunto forman un vector de ingreso neto de  $S$  elementos. Las salidas de las capas de neuronas forman un vector columna  $a$ . La expresión para  $a$  se muestra en la figura 6.5. Note que es común que el número de ingresos en una capa sea diferente del número de neuronas, (es decir,  $R$  no es necesariamente igual a  $S$ ).

Puede crear una sola capa (compuesta) de neuronas que tienen diferentes funciones de transferencia simplemente poniendo dos de las redes que se mostraron anteriormente en paralelo. Ambas redes tendrían las mismas entradas, y cada red podría crear alguna de las salidas.

Los elementos del vector de entrada ingresan en la red a través de la matriz de pesos  $w$ . Tenga en cuenta que los índices de fila sobre los elementos de la matriz  $w$  indican la neurona destino del peso, y los índices de las columnas indican qué fuente

**Figura 6.6:** Notación abreviada de una red de una sola capa con  $R$  elementos de ingreso y  $S$  neuronas.



**Fuente:** Elaboración propia.

es la entrada para ese peso.


$$w = \begin{bmatrix} w_{1,1} & w_{1,2} & \dots & w_{1,R} \\ w_{2,1} & w_{2,2} & \dots & w_{2,R} \\ \vdots & \vdots & \vdots & \vdots \\ w_{S,1} & w_{S,2} & \dots & w_{S,R} \end{bmatrix} \quad (6.3)$$

La red de una capa de  $S$  neuronas y  $R$  ingresos también se puede graficar en notación abreviada como se muestra a continuación en la figura 6.6. Aquí  $p$  es un vector de ingreso de longitud  $R$ ,  $w$  es una matriz de  $S \times R$ ,  $a$  y  $b$  son vectores de longitud  $S$ .

#### 6.1.4.2. Ingresos y Capas

Para describir las redes que tienen múltiples capas, la notación debe ser extendida. Específicamente, es necesario hacer una distinción entre las matrices de peso que están conectadas a los ingresos y las matrices de peso que están conectadas entre capas. También es necesario identificar el origen y destino de las matrices de peso. Vamos a llamar a las matrices de peso conectadas a las entradas pesos de entrada y a las matrices de peso conectadas a las salidas de capas pesos de capa. Además superíndices se utilizan para identificar el origen (segundo índice) y el destino (primer índice) para los diferentes pesos y otros elementos de la red. Para ilustrar la red de ingreso múltiple de una sola capa mostrada anteriormente se vuelve a graficar en la figura 6.7. Como puede ver, la matriz de peso conectada al vector de ingreso  $p$

**Figura 6.7:** Red de ingreso múltiple de una sola capa.



**Fuente:** Elaboración propia.

es etiquetada como una matriz de peso de entrada (IW 1,1), con origen 1 (segundo índice) y un destino 1 ( primer índice). Elementos de la capa 1, tales como sus umbrales, ingresos netos y salidas tienen un superíndice 1 para decir que ellos están asociados con la primera capa.

### 6.1.4.3. Múltiples Capas de Neuronas

Una red puede tener varias capas. Cada capa tiene una matriz de peso  $w$ , un vector umbral  $b$  y un vector de salida  $a$ . Para distinguir entre las matrices de peso, vectores de salida, etc., para cada una de estas capas en las figuras, el número de la capa se añade como un superíndice a la variable de interés. Usted puede ver el uso de esta notación de capa en la red de tres capas que se muestra en la figura 6.8 y en las ecuaciones en la parte inferior.


La red que se muestra en la figura 6.8 tiene  $R^1$  ingresos,  $S^1$  neuronas en la primera capa,  $S^2$  neuronas en la segunda capa, etc. Una constante 1 es alimentada para el umbral de cada neurona.

Tenga en cuenta que las salidas de cada capa intermedia son las entradas a la capa siguiente. Así la capa 2 puede ser analizada como una red de una capa con  $S^1$  ingresos,  $S^2$  neuronas y una matriz de peso  $w_2$  de  $S^2 \times S^1$ . El ingreso a la capa 2 es  $a^1$ ; la salida es  $a^2$ .

Las capas de una red de múltiples capas juegan diferentes papeles. Una capa que produce la salida de la red se llama una capa de salida. Todas las demás capas se denominan capas ocultas. La red de tres capas mostrada en la figura 6.8 tiene


una capa de salida (nivel 3) y dos capas ocultas (capas 1 y 2). Algunos autores se refieren a las entradas como una cuarta capa. La Caja de Herramientas de Redes Neuronales de MATLAB no utiliza esta denominación. La misma red de tres capas puede ser graficada usando notación abreviada como se muestra en la figura 6.9.

Figura 6.8: Red de ingreso múltiple de tres capas.



Fuente: Elaboración propia.

Figura 6.9: Notación abreviada de red de ingreso múltiple de tres capas.



Fuente: Elaboración propia.

Aquí se supone que la salida de la tercera capa,  $a^3$ , es la salida de la red de interés, y esta salida es etiquetada como  $y$ . Esta notación se utiliza para especificar la salida de las redes de múltiples capas.

#### **6.1.4.4. Funciones de procesamiento de ingresos y salidas**

Los ingresos a la red podrían haber sido asociados a las funciones de procesamiento. Las funciones de procesamiento transforman los datos de entrada de usuario a una forma que es más fácil o más eficaz para una red.

Similarmente, las salidas de la red también pueden tener asociadas funciones de procesamiento. Funciones de procesamiento se utilizan para transformar los vectores objetivo proporcionados por el usuario para el uso de la red. Luego, las salidas de la red son procesadas inversamente usando las mismas funciones para producir salida de datos con las mismas características como el objetivo original proporcionado por el usuario.

#### **6.1.4.5. Crear Objeto Red Neuronal**

La manera más fácil de crear una red neuronal es utilizar una de las funciones de creación de la red. Par investigar cómo se hace esto, usted puede crear una red simple de dos capas feedforward usando el comando `feedforwardnet`. Los subobjetos clave del objeto de red son `inputs`, `layers`, `outputs`, `biases`, `inputWeights` y `layerWeights`.

## **6.2. Redes Neuronales de Múltiples Capas y Entrenamiento de Retropropagación**

La red neuronal feedforward es el caballo de batalla de la Caja de Herramientas de Redes Neuronales de MATLAB. Aquí se muestra cómo se puede utilizar una red de múltiples capas. También se ilustra los procedimientos básicos para el diseño de cualquier red neuronal.<sup>1</sup>


El flujo de trabajo para el proceso de diseño general de redes neuronales de múltiples capas tiene siete pasos principales.

1. Recolectar datos.

---

<sup>1</sup>Información muy valiosa puede obtenerse también de la siguiente página web <http://www.mathworks.com/>.

**Figura 6.10:** Red de ingreso múltiple de una sola capa.



**Fuente:** Elaboración propia.

2. Crear la red.
3. Configurar la red.
4. Inicializar los pesos y umbrales.
5. Entrenar la red.
6. Validar la red (análisis post-entrenamiento).
7. Usar de la red.

El paso 1 podría suceder fuera del marco de la Caja de Herramientas de Redes Neuronales de MATLAB, pero este paso es crítico para el éxito del proceso de diseño.

## 6.2.1. Arquitectura de la Red Neuronal de Múltiples Capas

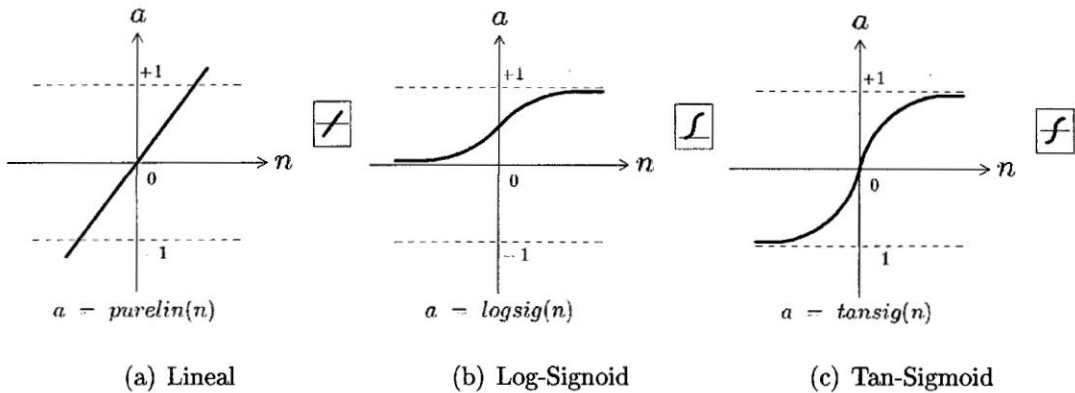
### 6.2.1.1. Neurona modelo (logsig, tansig, purelin)

Una neurona elemental con  $R$  ingresos es mostrada en la figura 6.10. Cada ingreso es ponderado con un  $w$  apropiado. La suma de los ingresos ponderados y los umbrales forman el ingreso a la función de transferencia  $f$ . Las neuronas pueden utilizar cualquier función de transferencia  $f$  diferenciable para generar su salida.

Las redes de múltiples capas a menudo utilizan la función de transferencia log-sigmoid logsig. La función logsig genera salidas entre 0 y 1 como entrada neta de

la neurona que va de infinito por la izquierda a infinito por la derecha. Alternativamente, las redes multicapas pueden usar las funciones de transferencia tan-sigmoid *tansig* y la función de transferencia lineal. Estas tres funciones se muestran en la figura 6.11.

**Figura 6.11:** Funciones de Transferencia.



**Fuente:** Elaboración propia.

Las tres funciones de transferencia descritas aquí son las funciones de transferencia más usadas comúnmente para redes de múltiples capas, pero otras funciones de transferencia diferenciables se pueden crear y usar si se desea.

### 6.2.1.2. Red neuronal feedforward

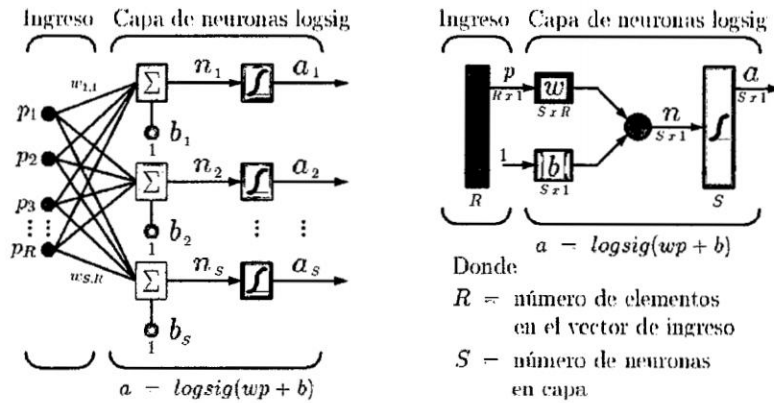
Una red de una sola capa de  $S$  neuronas *logsig* teniendo  $R$  ingresos se muestra a continuación en detalle completo en el lado izquierdo y con un diagrama de capas a la derecha en la figura 6.12.

Las redes feedforward a menudo tienen una o más capas ocultas de neuronas sigmoidales seguida seguida por una capa de salida de neuronas lineales. Capas múltiples de neuronas con funciones de transferencia no lineales permiten a la red aprender relaciones no lineales entre los vectores de ingreso y salida.

Por otro lado, si desea restringir las salidas de una red (tales como entre 0 y 1), entonces la capa de salida debería usar una función de transferencia sigmoideal (tal como *logsig*).


Para las redes de múltiples capas el número de capa determina el superíndice en la

**Figura 6.12:** Red de ingreso múltiple de una sola capa en notación abreviada.



**Fuente:** Elaboración propia.

**Figura 6.13:** Red de ingreso múltiple de dos capas en notación abreviada.



**Fuente:** Elaboración propia.

matriz de peso. La notación apropiada es usada en la red de dos capas tansig/purelin que se muestra en la figura 6.13.

Ahora que la red de múltiples capas ha sido definida, el proceso de diseño se describe en las siguientes secciones.

### 6.2.2. Preparar datos para redes de múltiples capas

Antes de comenzar el proceso de diseño de la red, primero recoger y preparar los datos de muestra. Es generalmente difícil incorporar el conocimiento previo en una red neuronal. Por lo tanto, la red sólo puede ser tan precisa como los datos que se utilizan para entrenar a la red. Es importante que los datos cubran el rango de ingresos para el que se utilizará la red. Redes de múltiples capas pueden ser entrenadas para generalizar así dentro del rango de ingresos para las que han sido

entrenadas. Sin embargo, no tienen la capacidad para extrapolar con precisión más allá de este rango, por lo que es importante que los datos de entrenamiento abarquen todo el rango del espacio de ingreso.

Una vez que se han recogido los datos, hay dos pasos que deben llevarse a cabo antes de que los datos se utilicen para entrenar a la red. Los datos deben ser preprocesados y necesitan ser divididos en subconjuntos.

### **6.2.3. Elegir funciones de procesamiento de ingresos y salidas de la red neuronal**


El entrenamiento de la red neuronal puede ser más eficiente si realiza ciertos pasos de preprocesamiento de los ingresos y objetivos de la red. Aquí se describen varias rutinas de preprocesamiento que se pueden utilizar. (La más común de estos se proporciona automáticamente al crear una red, y se convierten en parte del objeto de red, de modo que cada vez que la red es usada, los datos que entran en la red son preprocesados de la misma manera).

Si el ingreso es muy grande, entonces el peso debe ser muy pequeño con el fin de evitar que la función de transferencia se sature. Es una práctica estándar normalizar los ingresos antes de aplicarlos a la red. Generalmente, el paso de normalización es aplicado tanto a los vectores de ingreso y a los vectores objetivos en el conjunto de datos. De esta manera, la salida de la red cae en un rango normalizado. La salida de la red puede entonces ser transformada inversamente en las unidades de los datos del objetivo original cuando la red se pone en uso en el campo.

Es más fácil pensar en la red neuronal como que tienen un bloque de preprocesamiento que aparece entre la entrada y la primera capa de la red y un bloque de postprocesamiento que aparece entre la última capa de la red y la salida, como se muestra en la figura 6.14.

La mayor parte de las funciones de creación de la red en la caja de herramientas, incluyendo las funciones de creación de redes multicapas, tal como `feedforwardnet`, asignan automáticamente funciones de procesamiento a las entradas y salidas de la

**Figura 6.14:** Bloques de pre-procesamiento y post-procesamiento.



**Fuente:** Elaboración propia.

red. Estas funciones transforman los valores de ingreso y objetivo en valores que usted proporciona que son más adecuados para la formación de la red. Usted puede anular las funciones de procesamiento de ingreso y salida por defecto mediante el ajuste de las propiedades de la red.

Para la creación de funciones de redes multicapas, tal como feedforwardnet, las funciones de procesamiento de ingreso por defecto son removeconstantrows y mapminmax. El cuadro 6.1 lista las funciones de preprocesamiento y postprocesamiento más comunes. En la mayoría de los casos, usted no tendrá que utilizarlos directamente, ya que los pasos de preprocesamiento se convierten en parte del objeto de red. Cuando se simula o entrena la red, el preprocesamiento y postprocesamiento será hecho automáticamente.

**Cuadro 6.1:** Funciones de pre-procesamiento y post-procesamiento más comunes.

Función	Algoritmo
mapminmax	Normaliza ingresos/objetivos que caen en el rango [-1,1].
mapstd	Normaliza ingresos/objetivos para tener la media y varianza unitaria cero.
processpca	Extraer componentes principales del vector de ingreso.
fixunknowns	Procesos de ingreso desconocido.
removeconstantrows	Retirar ingresos/objetivos que son constantes.

**Fuente:** Elaboración Propia.

#### **6.2.4. Representando objetivos desconocidos**

Objetivos desconocidos pueden ser representados con valores NaN. No queremos que los valores objetivo desconocidos tengan un impacto en el entrenamiento, pero si una red tiene varias salidas, algunos elementos de cualquier vector objetivo pueden ser conocidos, mientras que otros son desconocidos. Una solución podría ser eliminar el vector objetivo desconocido parcialmente y su vector de ingreso asociado del conjunto de entrenamiento, pero implica la pérdida de los buenos valores objetivo. Una mejor solución es representar esos objetivos desconocidos con valores NaN.

Todas las funciones de interpretación de la caja de herramientas ignoran esos objetivos para propósitos de cálculo del rendimiento y derivados del funcionamiento.

#### **6.2.5. Dividir datos para el entrenamiento óptimo de la Red Neuronal**

Durante el entrenamiento de redes de múltiples capas, la práctica común es primero dividir los datos en tres subconjuntos. El primer subconjunto es el conjunto de entrenamiento, que se utiliza para calcular el gradiente y actualizar los pesos y umbrales de la red. El segundo subconjunto es el conjunto de validación. El error en el conjunto de validación es monitoreado durante el proceso de entrenamiento. El error de validación normalmente decrece durante la fase inicial de entrenamiento, como lo hace el error del conjunto de entrenamiento. Sin embargo, cuando la red empieza a sobreajustar los datos, el error en el conjunto de validación típicamente comienza a aumentar. Los pesos y umbrales de la red se guardan en el mínimo del error del conjunto de validación. El error del conjunto de prueba no es usado durante el entrenamiento, pero es usado para comparar diferentes modelos. Es también útil trazar el error del conjunto de prueba durante el proceso de entrenamiento. Si el error en el conjunto de prueba alcanza un mínimo en un número de iteración significativamente diferente que el error del conjunto de validación, esto podría indicar una pobre división del conjunto de datos. Hay cuatro funciones para dividir los datos en los conjuntos de entrenamiento, validación y prueba, ellos se muestran en el

cuadro 7.6. La división de datos es normalmente realizada automáticamente cuando entrena la red.

**Cuadro 6.2:** Funciones para dividir datos.

Función	Algoritmo
dividerand	Divide los datos aleatoriamente (por defecto).
divideblock	Divide los datos en bloques contiguos.
divideint	Divide los datos mediante una selección intercalada.
divideind	Divide los datos por el índice.

**Fuente:** Elaboración Propia.

### 6.2.6. Crear, Configurar e inicializar Redes Neuronales de Múltiples Capas

Después que los datos han sido recolectados, el siguiente paso en el entrenamiento de una red es crear el objeto de red. La función `feedforwardnet` crea una red feedforward de múltiples capas. Si esta función se invoca sin argumentos de ingreso, entonces un objeto de red por defecto es creado que no ha sido configurado. La red resultante se puede configurar con el comando `configure`.

### 6.2.7. Otras arquitecturas relacionadas

Mientras las redes feedforward de dos capas puede potencialmente aprender virtualmente cualquier relación ingreso-salida, las redes feedforward con más capas podrían aprender relaciones complejas con mayor rapidez. Para la mayoría de los problemas, lo mejor es empezar con dos capas y luego incrementar a tres capas, si el rendimiento con dos capas no es satisfactorio. La función `cascaforwardnet` crea redes cascade-forward. Estas son similares a las redes feedforward, pero incluyen una conexión de peso desde el ingreso a cada capa y a partir de cada capa a las capas sucesivas. Las conexiones adecuadas pueden mejorar la velocidad a la que la red aprende la relación deseada. La función `patternnet` crea una red que es muy similar

a feedforwardnet, excepto que usa la función de transferencia tansig en la última capa.

### 6.2.8. Inicializando pesos (init)

Antes de entrenar una red feedforward, debe inicializar los pesos y umbrales. El comando `configure` automáticamente inicializa los pesos, pero es posible que desee reinicializar ellos. Esto se hace con el comando `init`. Esta función toma un objeto de red como ingreso y retorna un objeto de red con todos los pesos y umbrales inicializados.

### 6.2.9. Entrenar y aplicar Redes de Neuronas de Múltiples Capas

Cuando los pesos y umbrales de la red son inicializados, la red está lista para el entrenamiento. El proceso de entrenamiento requiere una red de adecuado comportamiento de ingresos  $p$  y objetivos  $t$ .

El proceso de entrenamiento en una red neuronal involucra la sintonización de los valores de los pesos y umbrales de la red para optimizar el entrenamiento de la red, tal como se define por la función de rendimiento de la red `net.performFcn`. La función de rendimiento por defecto para redes feedforward es el error cuadrático promedio entre las salidas de la red  $a$  y el objetivo de las salidas  $t$ . Se define en la ecuación 6.4:

$$F = mse = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad (6.4)$$

Hay dos maneras diferentes en que el entrenamiento puede ser implementado: el modo incremental y el modo por lotes. En el modo incremental, el gradiente es calculado y los pesos son actualizados después de que cada ingreso es aplicado a la red. En el modo por lotes, todos los ingresos en el conjunto de entrenamiento son aplicados a la red antes de que los pesos son actualizados. Para la mayoría de problemas, cuando se utiliza la Caja de Herramientas de Redes Neuronales de

MATLAB, el entrenamiento por lotes es significativamente más rápido y produce errores más pequeños que el entrenamiento incremental.

Para el entrenamiento de redes feedforward de múltiples capas, cualquier algoritmo de optimización numérica estándar puede ser usado para optimizar la función de rendimiento, pero hay algunas otras claves que han mostrado un rendimiento excelente para entrenamiento de Redes Neuronales.

Estos métodos de optimización utilizan ya sea el gradiente del rendimiento de la red con respecto a los pesos de la red, o el Jacobiano de los errores de la red con respecto a los pesos. El gradiente y el Jacobiano son calculados usando una técnica llamada el algoritmo de Retro-Propagación, que implica la realización de cálculos hacia atrás a través de la red. El cálculo de Retro-Propagación se deriva usando la regla de la cadena del cálculo.

### 6.2.10. Algoritmos de entrenamiento

Como una ilustración de cómo funciona el entrenamiento, considerar la más simple optimización del algoritmo de gradiente descendiente. Si actualiza los pesos y umbrales de la red en la dirección en la que la función de rendimiento decrece con mayor rapidez la negativa del gradiente. Una iteración de este algoritmo se puede escribir como la ecuación 6.5

$$x_{k+1} = x_k - \alpha_k g_k \quad (6.5)$$

donde  $x_k$  es un vector de pesos y umbrales actuales,  $g_k$  es el gradiente actual y  $\alpha_k$  es la razón de aprendizaje. Esta ecuación se itera hasta que la red converge. Una lista de los algoritmos de entrenamiento que están disponibles en la Caja de Herramientas de Redes Neuronales de MATLAB y métodos basados que usan el gradiente o el Jacobiano, se muestra en el cuadro 6.3.

**Cuadro 6.3:** Algoritmos de entrenamiento.

Función	Algoritmo
trainlm	Levenberg-Marquardt.
trainbr	Regularización Bayesiana.
trainbfg	BFGS Quasi-Newton.
trainrp	Retropropagación resistente.
trainscg	Gradiente conjugado escalado.
traincgb	Gradiente conjugado con reinicio Powell/Beale.
traicgf	Gradiente conjugado Fletcher-Powell.
traicgp	Gradiente conjugado Polak-Ribière.
trainoss	Uno paso secante.
traicdx	Razón de Gradiente descendente con aprendizaje variable.
traingdm	Gradiente descendente con momento.
traingd	Gradiente descendente.

**Fuente:** Elaboración Propia.

La función de entrenamiento más rápida es generalmente `trainlm`, y es la función de entrenamiento por defecto para `feedforwardnet`. El método Quasi-Newton, `trainbfg`, es también bastante rápido. Ambos de estos métodos tienden a ser menos eficientes para grandes redes (con miles de pesos), ya que requieren más memoria y más tiempo de cálculo para estos casos. Las funciones de entrenamiento `trainscg` y `trainrp` son buenas opciones. Sus requerimientos de memoria son relativamente pequeños y aún son mucho más rápidos que los algoritmos de descenso del gradiente estándar.

Además la red de múltiples capas se refiere a veces como una red de Retropropagación. Sin embargo, la técnica de Retropropagación que se utiliza para calcular gradientes y jacobianos en una red de múltiples capas también se puede aplicar a muchas diferentes arquitecturas de red. De hecho, los gradientes y jacobianos para cualquier red que tiene funciones de transferencia diferenciables, funciones de peso y funciones de ingreso neto puede ser calculadas usando la Caja de Herramientas de Redes Neuronales de MATLAB a través de un proceso de Retropropagación. Usted

puede incluso crear sus propias redes personalizadas y luego entrenarlos utilizando cualquiera de las funciones de entrenamiento en el cuadro 6.3. Los gradientes y jacobianos se calculan automáticamente.

### **6.2.11. Uso de la red**

Después de que la red es entrenada y validada, el objeto de red se puede utilizar para calcular la respuesta de la red a cualquier entrada.

Cada vez que una red neuronal se entrena, puede resultar en una diferente solución debido a diferentes valores iniciales de pesos y umbrales y diferentes divisiones de datos en los conjuntos de entrenamiento, validación y prueba. Como resultado, diferentes redes neuronales entrenadas en el mismo problema pueden dar diferentes salidas para la misma entrada. Para asegurarse de que se ha encontrado una red neuronal de una buena precisión, reentrenar varias veces. Hay varias otras técnicas para la mejora en las soluciones iniciales si se desea una precisión mayor.

### **6.2.12. Analizar el rendimiento de la red neuronal después del entrenamiento**

Cuando el entrenamiento se ha completado, se puede comprobar el rendimiento de la red y determinar si algún cambio necesita ser hecho en el proceso de entrenamiento, la arquitectura de la red o el conjunto de datos. Primero revisar el registro de entrenamiento, `tr`, que es el segundo argumento devuelto desde la función de entrenamiento.

Esta estructura contiene toda la información concerniente al entrenamiento de la red. La estructura `tr` también realiza un seguimiento de varias variables durante el curso de entrenamiento, tales como el valor de la función de entrenamiento, la magnitud del gradiente, etc.

El siguiente paso en la validación de la red es crear un trazo de regresión, que muestra la relación entre las salidas de la red y los objetivos. Si el entrenamiento de la red fue perfecto, la salida y los objetivos de la red podrían ser exactamente

iguales, pero la relación no suele ser perfecta en la práctica.

### **6.2.13. Mejorar los resultados**

Si la red no es suficientemente precisa, usted puede inicializar la red y el entrenamiento de nuevo. Cada vez que inicialice una red feedforward, los parámetros de la red son diferentes y pueden producir diferentes soluciones.

Como un segundo enfoque, usted puede incrementar el número de neuronas ocultas por encima de 20. Un mayor número de neuronas en la capa oculta de la red da mayor flexibilidad porque la red tiene más parámetros que puede optimizar.

Una tercera opción es tratar una función de entrenamiento diferente. Entrenamiento de Regularización Bayesiana con `trainbr`, por ejemplo, puede a veces producir una mejor capacidad de generalización que el uso de principios de parada.

Por último, trate de usar los datos de entrenamiento adicionales. Proporcionar datos adicionales para la red es más probable para producir una red que generalice bien los resultados.

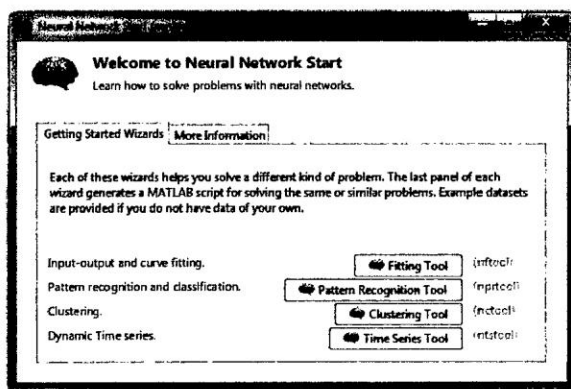
### **6.2.14. Limitaciones y precauciones**

Normalmente se usaría el entrenamiento Levenberg-Marquardt para redes de tamaño pequeño y medio, si tiene suficiente memoria disponible. Si la memoria es un problema, entonces hay una variedad de otros algoritmos rápidos disponibles. Para redes grandes es probable que desee utilizar `trainscg` o `trainrp`.

Las redes de múltiples capas son capaces de realizar casi cualquier cálculo lineal o no lineal, y pueden aproximar cualquier función razonable arbitrariamente bien. Sin embargo, mientras que la red está entrenando podría teóricamente ser capaz de realizar correctamente, Retropropagación y sus variaciones no siempre encuentran una solución.

Las redes también son sensibles al número de neuronas en sus capas ocultas. Muy pocas neuronas pueden conducir a un bajo ajuste. Demasiadas neuronas pueden contribuir a sobreajuste, en la que todos los puntos de entrenamiento están bien

**Figura 6.15:** Inicio de la Caja de Herramientas de Redes Neuronales.



**Fuente:** Matlab 2014a.

equipados, pero la curva de ajuste oscila salvajemente entre estos puntos.

## 6.3. Ajustando una función

### 6.3.1. Inicio de Red Neuronal (nnstart)

Al editar el comando `nnstart` en la ventana principal de Matlab aparece la figura 6.15. Aquí cada uno de sus asistentes le ayuda a resolver un problema diferente. El último panel de cada asistente genera una secuencia de comandos de MATLAB para la solución de los mismos o problemas similares. Ejemplo de conjuntos de datos son proporcionados si usted no tiene los datos de su problema.

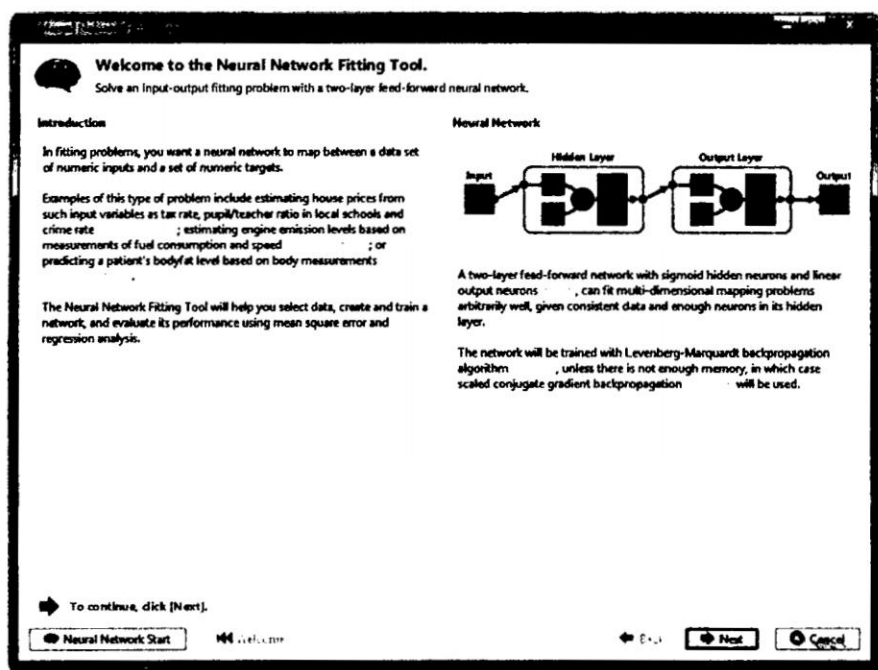
Al seleccionar el asistente Fitting tool (Ajustando una función), aparece la figura 6.16 que muestra una breve introducción de la herramienta de ajuste y explicación de los comandos utilizados para la Red Neuronal.

### 6.3.2. Herramienta de ajuste de Red Neuronal (nftool)

En los problemas de ajuste, usted quiere una red neuronal para asignar entre un conjunto de datos de ingresos numéricos y un conjunto de objetivos numéricos.

La herramienta de ajuste de red neuronal le ayudará a seleccionar los datos, crear y entrenar a una red, y evaluar su rendimiento mediante el error cuadrático medio

Figura 6.16: Ventana de la Herramienta de ajuste de Red Neuronal.



Fuente: Matlab 2014a.

y el análisis de regresión.

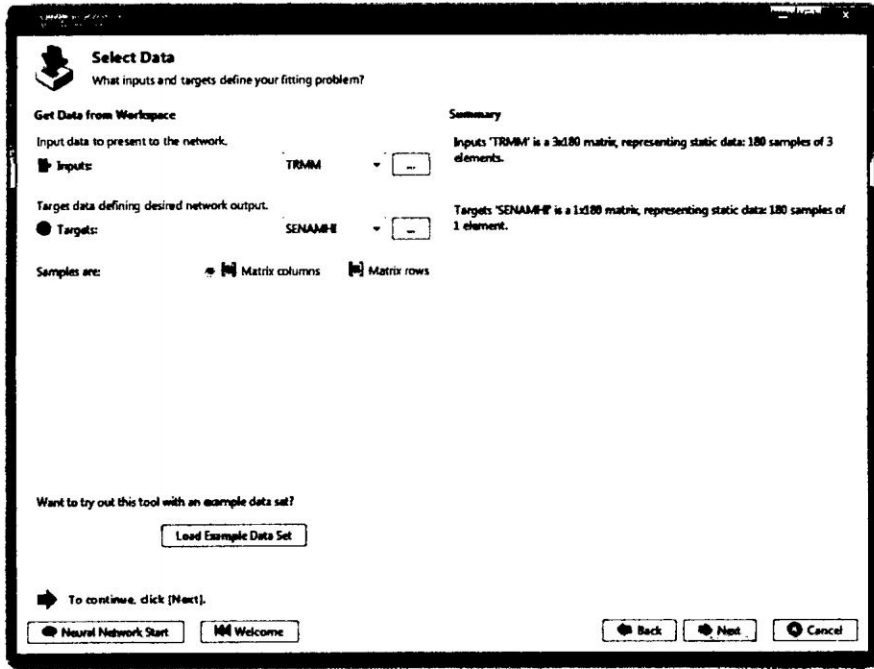
Una red feed-forward de dos capas con neuronas ocultas sigmoideas y neuronas de salida lineales (fitnet), puede ajustar problemas de asignación multidimensionales arbitrariamente bien, teniendo en cuenta los datos consistentes y suficientes neuronas en su capa oculta.

Al hacer click en Next en la ventana del nftool, se muestra la figura 6.17, en donde puede seleccionar los conjuntos de datos de ingreso y objetivos previamente establecidos en la ventana de comandos o en un archivo script.

Nuevamente al hacer click en Next, se muestra la figura 6.18, en donde puede seleccionar los porcentajes para los subconjuntos de entrenamiento, validación y prueba. A continuación se da una breve descripción del empleo de los subconjuntos:

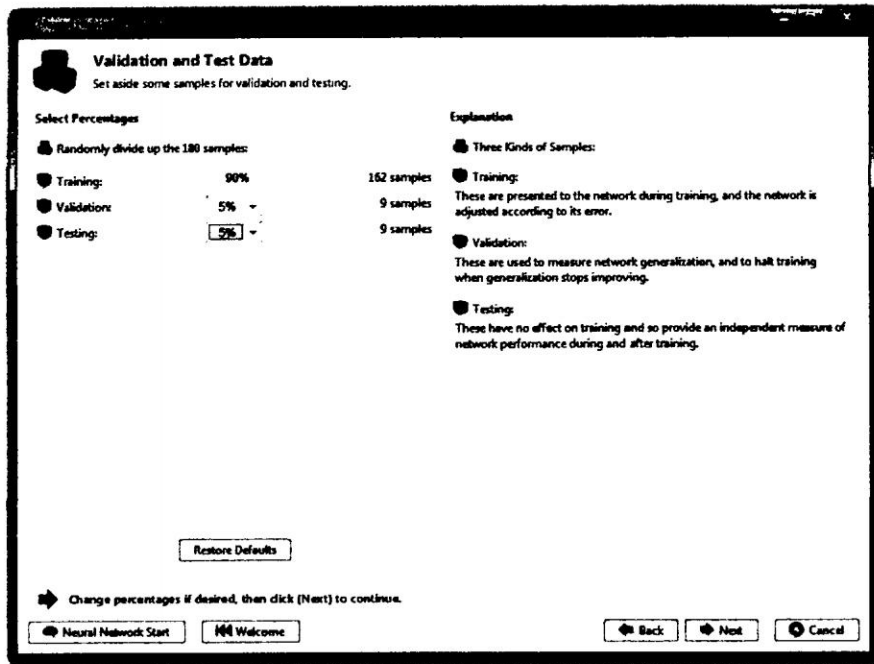
- **Subconjunto de entrenamiento.** Estos se presentan a la red durante el entrenamiento, y la red se ajusta de acuerdo a su error.
- **Subconjunto de validación.** Estos se utilizan para medir la generalización de la red, y para detener la formación, cuando se detiene la mejora de genera-

Figura 6.17: Ventana de selección de ingresos y objetivos.



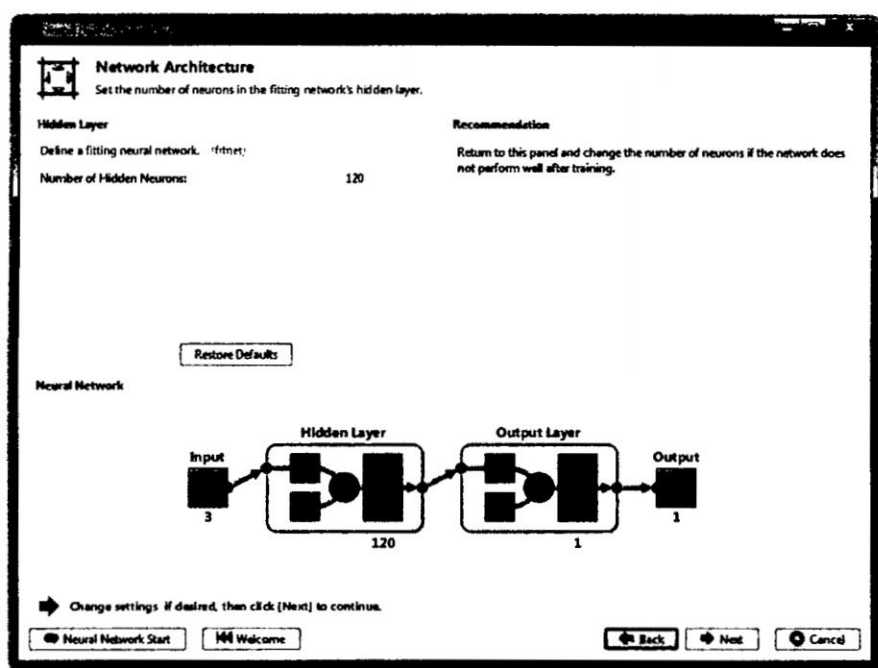
Fuente: Matlab 2014a.

Figura 6.18: Ventana de datos de validación y prueba. Fuente: Fuente: Matlab 2014a.



Fuente: Elaboración propia.

Figura 6.19: Ventana de arquitectura de la Red Neuronal.



Fuente: Matlab 2014a.

lización.

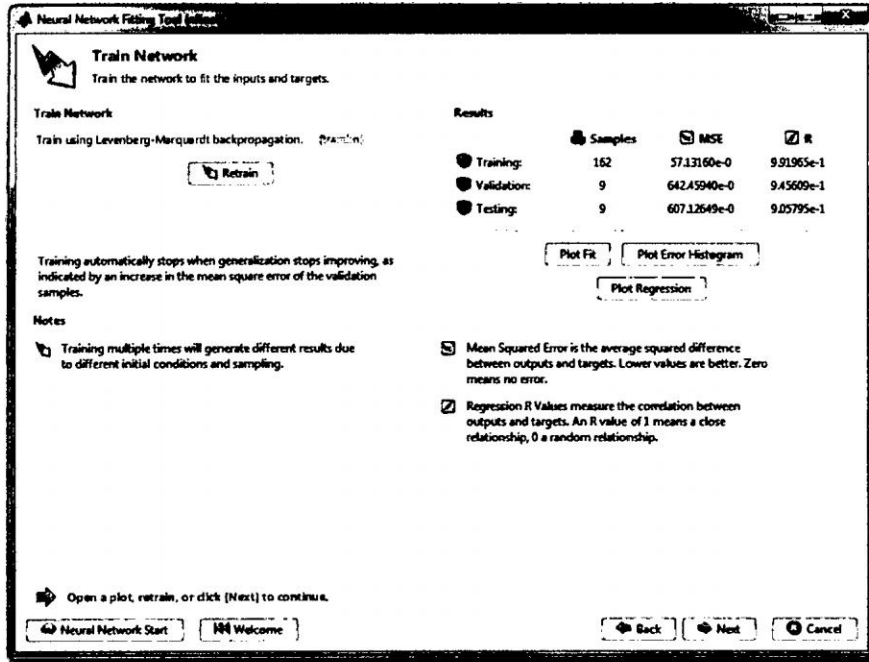
- **Subconjunto de prueba.** Estos no tienen efecto sobre la formación y así lo disponga una medida independiente de rendimiento de la red durante y después del entrenamiento.

Al hacer click en Next, se muestra la figura 6.19, en donde puede seleccionar el número de neuronas en la capa oculta y así definir la arquitectura de la red que es mostrada en la parte inferior.

Al hacer click en Next, se muestra la figura 6.20, en donde se puede iniciar el entrenamiento de la Red Neuronal haciendo click en Retrain.

La Herramienta de ajuste de Red Neuronal también muestra una aplicación interactiva (ver figura 6.21) para mostrar el progreso del entrenamiento de la Red Neuronal. Si hace clic en Regression en la ventana interactiva del progreso de entrenamiento, se puede realizar una regresión lineal entre las salidas de la red y los objetivos correspondientes.

Figura 6.20: Ventana de entrenamiento de la Red Neuronal.



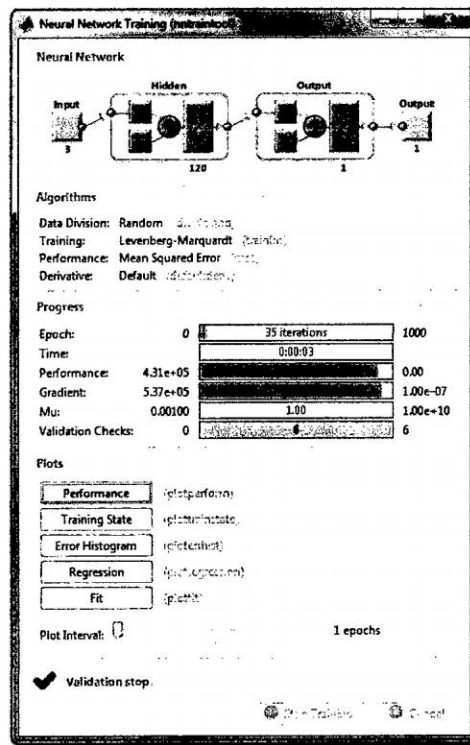
Fuente: Matlab 2014a.

Para que el resultado de la aplicación tenga el resultado razonable, se de tener en cuenta las siguientes consideraciones:

- El error medio cuadrático final es pequeño.
- El error del subconjunto de prueba y el error del subconjunto de validación deben poseer características similares.
- Sobreajuste no significativo debe producirse durante las iteraciones (donde se produce el mejor rendimiento de validación).

Para mayor información acerca del uso de la herramienta de ajuste de Red Neuronal revisar la referencia [13], en donde podrá encontrar información complementaria a la presente investigación relacionada a la Redes Neuronales Dinámicas.

Figura 6.21: Ventana interactiva del progreso del entrenamiento de la Red Neuronal.




Fuente: Elaboración propia.

## Capítulo 7

# Validación de la precipitación derivada del TRMM sobre la Cuenca del Río Cachi

Figura 7.1: El Satélite TRMM.



Fuente: Página Web del TRMM.

## 7.1. Introducción

La presente investigación será aplicada a la Cuenca del Río Cachi, para estimar valores de precipitación in situ a partir de valores de precipitaciones mensuales derivadas del algoritmo 3B43 V7 del TRMM. La determinación del potencial hídrico para su aprovechamiento es de vital importancia para el departamento de Ayacucho. El Satélite TRMM se encuentra orbitando la Tierra como se muestra en la figura 7.1 a partir del año 1998 y desde entonces datos de precipitaciones diarias y mensuales pueden ser descargados de su página web<sup>1</sup>.

En el Perú las medidas de las variables hidrometeorológicas están a cargo del Servicio Nacional de Meteorología e Hidrología, SENAMHI<sup>2</sup>. La mayoría de los datos hidrometeorológicos están relacionados a variables climáticas.

## 7.2. Área de estudio

### 7.2.1. Ubicación y Localización

La Cuenca del Río Cachi, se encuentra ubicada en la Sierra Central de los Andes peruanos: geográficamente está comprendida entre los paralelos 13.0° y 13.5° de latitud Sur, y los meridianos 74.0° y 74.5° de longitud Oeste; se extiende altitudinalmente desde los 2250 hasta los 5550 metros sobre el nivel del mar, políticamente pertenece al departamento de Ayacucho, abarca las provincias de Huamanga, Huanata y Cangallo. El área de estudio comprende básicamente la Cuenca del Río Cachi, que es denominado como tal a partir de la confluencia de los ríos Chicllarazo y Apacheta. Según la estación climatológica de Huamanga, representativa para la zona de estudio, se tiene una temperatura del aire media mensual de 15.4°C con medias máximas de 25.3°C en noviembre y medias mínimas de 4.7°C en julio habiendo un periodo frío de mayo a agosto y un periodo caliente de septiembre a abril.

---

<sup>1</sup>La página web para descargar datos de precipitación mensuales del TRMM es [http://disc2.nascom.nasa.gov/Giovanni/tovas/TRMM\\_V7.3B43.2.shtml](http://disc2.nascom.nasa.gov/Giovanni/tovas/TRMM_V7.3B43.2.shtml)

<sup>2</sup>Página web oficial [www.senamhi.gob.pe](http://www.senamhi.gob.pe)

## 7.3. Datos y Metodología

### 7.3.1. Datos utilizados

#### 7.3.1.1. Delimitación de la Cuenca del Río Cachi

La Cuenca del Río Cachi limita con las cuencas de Huanta (Norte), Huancapi (Sur), San Miguel (Oeste) y Huachocolpa (Este), tiene una extensión aproximada de 3602.08 km<sup>2</sup> y tiene como subcuencas principales a la de los ríos Apacheta - Choccoro (444 km<sup>2</sup>), Chicllarazo - Allpachaca (660 km<sup>2</sup>) y Vinchos - Cachi (771 km<sup>2</sup>) (Referencia [9]).

La delimitación geográfica de la Cuenca del Río Cachi se realizó a partir de las cartas geográficas nacionales obtenidas de IGN <sup>3</sup> en formato dwg; logrando identificar subcuencas, ríos y demás características relacionadas a la Cuenca del Río Cachi. La zona de estudio se enmarca dentro de las coordenadas geográficas correspondientes a las cartas nacionales que corresponden a las hojas 26-O, 26-Ñ, 27-O y 27-Ñ.

Hidrográficamente pertenece a la Vertiente del Atlántico, es un tributario del Río Mantaro por la margen derecha.

La Cuenca del Río Cachi presenta como características principales: topografía irregular, pendientes fuertes, laderas muy inclinadas y pequeñas lomas, quebradas profundas con pendientes pronunciadas, suelos con erosiones moderadas a fuertes (Referencia [9]). La precipitación media anual es de 765 a 1040.50 mm, variando de acuerdo a la altitud de la topografía de la Cuenca (Referencia [9]).

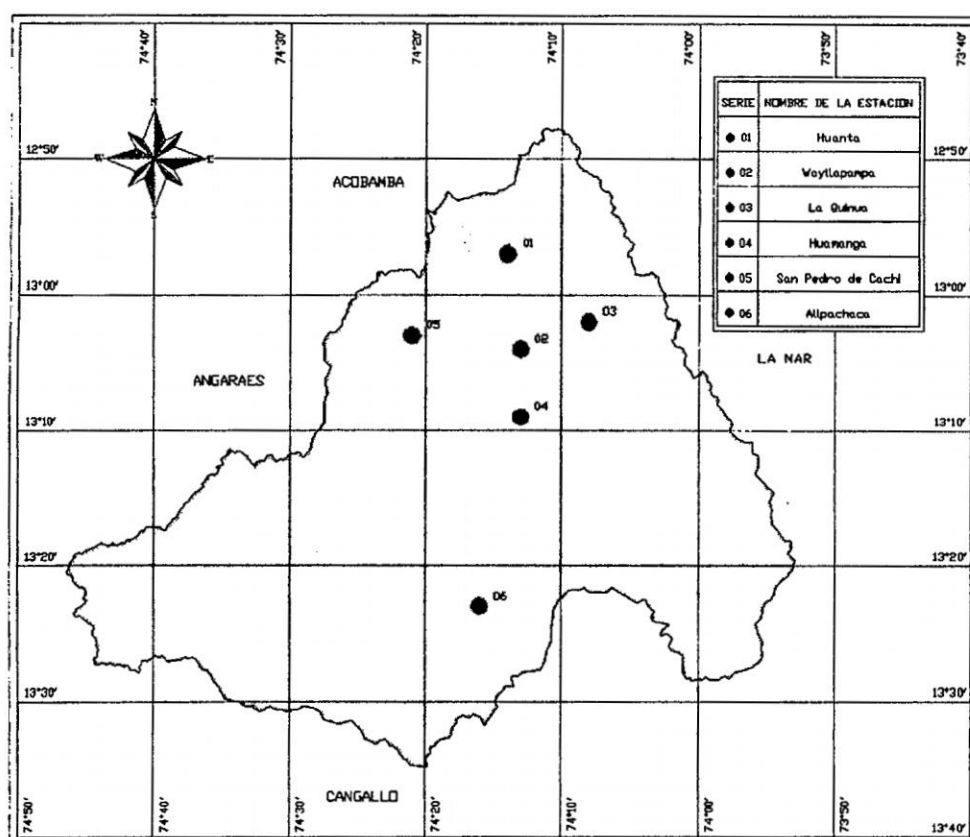
El área de estudio presenta un clima templado a cálido variando con la altitud de la Cuenca. Las temperaturas más bajas se presentan en los meses de Mayo a Julio con valores que llegan hasta los -7.0°C (Referencia [9]).

La ubicación de cada una de estas estaciones sobre la Cuenca del Río Cachi en coordenadas geográficas se muestra en la figura 7.2. Las coordenadas geográficas se emplean aquí debido a que en la página Web del TRMM se requiere ingresar la ubicación en este tipo de coordenadas.

---

<sup>3</sup>Página web oficial <http://www.ign.gob.pe/>

**Figura 7.2:** Cuenca del Río Cachi y Ubicación de las Estaciones Pluviométricas.



Fuente: Elaboración Propia.

### 7.3.1.2. Datos del algoritmo 3B43 V7 del TRMM

La recolección de precipitación mensual mediante la Misión de la Medición de LLuvias Tropicales a partir del algoritmo 3B43 V7 en 6 ubicaciones sobre la Cuenca del Río Cachi es utilizada en este estudio. Series, Nombres, Coordenadas Geográficas y Altitud de estaciones sintéticas son presentados en el cuadro 7.1. Los datos del algoritmo 3B43 V7 del TRMM utilizados son de libre acceso disponible a partir de la base de datos de la NASA. El algoritmo 3B43 V7 proporciona la mejor estimación de la precipitación mensual total en un registro completo a partir de enero del año 1998 a diciembre del año 2007. Este conjunto de datos es el resultado de la combinación de los conjuntos de datos de precipitación. Los tipos comunes de errores de las mediciones del TRMM se deben a las características de muestreo discretos. De hecho, el satélite TRMM se encuentra en una órbita terrestre baja de  $\approx 350$

kilometros de altura; los sensores de lluvia toman muestras de la atmósfera regional sólo a intervalos de tiempo discretos, a veces faltan las tormentas de corta duración.

**Cuadro 7.1:** Estaciones Sintéticas de la Medición de la Precipitación Global.

Medición de la Precipitación de Lluvias Tropicales (TRMM)				
Serie	Nombre de la Estación Sintética	Latitud (Grados)	Longitud (Grados)	Altitud (msnm)
1	Estación Sintética Huanta	12°56'55"S	74°14'13"W	2682
2	Estación Sintética Wayllapampa	13°04'36"S	74°13'01"W	2470
3	Estación Sintética La Quinua	13°02'02"S	74°08'07"W	3316
4	Estación Sintética Huamanga	13°09'01"S	74°13'01"W	2761
5	Estación Sintética San Pedro de Cachi	13°03'55"S	74°21'31"W	2990
6	Estación Sintética Allpachaca	13°23'01"S	74°16'01"W	3600

**Fuente:** Elaboración Propia.

A continuación se muestra en el cuadro 7.2 los datos de precipitaciones mensuales provenientes del Algoritmo 3B43 V7 del TRMM, que serán parte de los datos de ingreso para nuestro modelo de Redes Neuronales Artificiales.

En el modelo de Redes Neuronales fueron descartados las estaciones pluviométricas **Huamanga** y **Allpachaca** por poseer datos provenientes del SENAMHI en tiempos diferentes al periodo comprendido entre los años 2009 y 2013; También fue descartado la estación pluviométrica **Wayllapampa** por poseer datos provenientes del algoritmo 3B43 V7 del TRMM iguales a los de la estación La Quinua. Después de gran cantidad de pruebas de ingreso de datos se encontró que la matriz de ingreso sólo debiera contener datos representativos del mes, año y precipitación; descartando ingresos relacionados a la altura y ubicación geográfica de las estaciones por su implicancia negativa en las salidas de la red relacionadas a otras ubicaciones geográficas que no participaron en este estudio. Este ingreso se ordena en una matriz de 3 filas y 180 columnas; donde la primera fila identifica los meses de acuerdo a una numeración ( 1 para el mes de Enero, 2 para el mes de Febrero, etc.) la segunda fila indica el año en el que ocurre la precipitación y la tercera fila contiene los valores de precipitación obtenidos del algoritmo 3B43 V7 del TRMM. La matriz de ingreso de datos completa se muestra en el cuadro 7.5.

**Cuadro 7.2:** Precipitación mensual de la Estaciones Sintéticas (TRMM).

Misión de la Medición de Lluvias Tropicales (TRMM)												
Precipitación mensual de la Estación Sintética Huanta (mm)												
Año	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
2009	113.9830	172.3130	114.4070	104.0990	37.6143	10.1245	16.6350	52.3879	40.6523	63.9543	60.9438	92.2513
2010	155.5940	75.9840	140.8390	54.1633	44.3207	8.0093	21.1814	38.9831	34.8467	86.5043	44.9477	103.7980
2011	131.3240	160.4510	234.4430	84.5714	38.7978	1.6459	31.1045	16.0016	45.3819	57.4980	113.9980	148.0290
2012	135.2180	172.7160	118.2520	69.9031	14.6823	15.9119	22.8793	43.6476	73.4892	64.9423	82.2880	149.0470
2013	107.9640	129.9560	97.4443	48.4168	21.4857	8.8660	30.1145	44.4543	71.8208	73.9590	82.2263	137.9450
Precipitación mensual de la Estación Sintética La Quinua (mm)												
Año	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
2009	121.5410	149.7970	101.4770	75.3891	35.0727	0.6329	17.6206	24.1954	17.8437	51.1599	59.6677	134.5720
2010	171.9470	86.8840	101.9430	32.3946	20.5647	0.3712	8.6787	17.4365	29.9609	59.7806	36.4349	103.4350
2011	163.1500	194.8160	237.8900	57.5143	22.0260	1.8743	25.7613	10.7689	40.7528	55.4625	102.5450	142.5610
2012	135.0490	183.3930	124.8770	56.9612	15.9437	6.5833	15.6615	19.1798	54.9732	46.1977	84.2224	161.0510
2013	100.7590	137.5280	139.5270	33.4409	21.8446	7.4635	20.0796	26.8259	32.9407	80.9127	81.4774	152.2050
Precipitación mensual de la Estación Sintética San Pedro de Cachi (mm)												
Año	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
2009	122.3420	134.9640	74.6208	64.1177	31.1638	4.3385	19.9760	21.0657	14.3045	46.1277	53.4620	119.7820
2010	203.2880	85.8590	99.0827	35.0612	20.3236	0.0402	1.9940	17.5798	24.4064	54.8699	25.2692	88.3064
2011	161.9170	176.0780	242.3460	55.5447	19.9273	0.7910	25.3646	10.9906	38.8448	49.7570	78.1859	131.7980
2012	140.5550	166.7690	122.7550	58.5693	17.8688	5.2663	13.8485	14.5393	54.7764	30.4864	64.3260	139.9590
2013	105.0920	141.7630	90.7801	29.2451	15.7634	15.9513	10.1121	22.6594	30.5166	64.6093	65.1074	182.0600

Fuente: Elaboración Propia.

### 7.3.1.3. Datos del SENAMHI

La recolección de precipitación diaria por el Servicio Nacional de Meteorología e Hidrología (SENAMHI) en 6 ubicaciones sobre la Cuenca del Río Cachi es utilizada en este estudio. Series, Nombres, Coordenadas Geográficas y Altitud de estaciones pluviométricas son presentados en el cuadro 7.3. Todas la estaciones pluviométricas empleadas en este estudio se encuentran por debajo de los 3000 msnm a excepción de las estaciones pluviométricas La Quinua y Allpachaca que se encuentran a 3316 y 3600 msnm respectivamente. Las mediciones in situ encajan en la categoría de error de muestreo, que van desde errores en el manejo de los equipos por personal de campo para superar los impactos en las mediciones. Los datos han pasado las evaluaciones de calidad rigurosos y procesos de control de calidad por el SENAMHI. El SENAMHI verificó el nivel de coherencia entre los valores diarios y mensuales dados por los operadores. De la misma manera que en el caso de los datos del

TRMM, aquí se muestra en el cuadro 7.4 los datos de precipitaciones mensuales provenientes del SENAMHI, que serán los objetivos para nuestro modelo de Red Neuronal. Estos objetivos se ordenan en una matriz de orden 1 x 180, el cual contiene las precipitaciones Pluviométricas mensuales obtenidas a partir de la acumulación de precipitaciones diarias del SENAMHI. La matriz objetivo completa se muestra en el cuadro 7.5.

**Cuadro 7.3: Estaciones Pluviométricas del SENAMHI.**

Servicio Nacional de Meteorología e Hidrología (SENAMHI)				
Serie	Nombre de la Estación Pluviométrica	Latitud (Grados)	Longitud (Grados)	Altitud (msnm)
1	Estación pluviométrica Huanta	12°56'55"S	74°14'13"W	2682
2	Estación pluviométrica Wayllapampa	13°04'36"S	74°13'01"W	2470
3	Estación pluviométrica La Quinua	13°02'02"S	74°08'07"W	3316
4	Estación pluviométrica Huamanga	13°09'01"S	74°13'01"W	2761
5	Estación pluviométrica San Pedro de Cachi	13°03'55"S	74°21'31"W	2990
6	Estación pluviométrica Allpachaca	13°23'01"S	74°16'01"W	3600

**Fuente:** Elaboración Propia.

**Cuadro 7.4: Precipitación mensual de la Estaciones Pluviométricas (SENAMHI).**


Servicio Nacional de Meteorología e Hidrología (SENAMHI)												
Precipitación mensual de la Estación Pluviométrica Huanta (mm)												
Año	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
2009	91.9000	120.6000	71.9000	48.8000	29.9000	1.1000	10.3000	7.5000	10.2000	17.2000	33.7000	49.4000
2010	163.4000	61.1000	92.3000	22.1000	0	0	0	4.0000	7.0000	40.8000	29.4000	137.9000
2011	208.8000	93.1000	78.3000	29.5000	7.6000	0.2000	1.3000	0.2000	13.9000	35.6000	58.6000	92.0000
2012	89.9000	139.5000	38.6000	50.3000	8.3000	5.7000	6.3000	6.2000	21.5000	21.6000	37.3000	130.9000
2013	132.1000	98.0000	76.9000	34.7000	0	1.6000	1.3000	39.2000	2.4000	27.1400	36.8600	89.5600
Precipitación mensual de la Estación Pluviométrica La Quinua (mm)												
Año	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
2009	150.5000	174.8000	59.5000	55.9000	26.7000	0.4000	5.0000	8.7000	36.7000	50.6000	113.7000	109.9000
2010	138.7000	120.2000	124.8000	23.0000	8.6000	0	6.6000	15.0000	17.3000	91.2000	33.9000	132.9000
2011	188.9000	203.8000	170.4000	61.6000	17.3000	5.6000	6.6000	5.2000	67.7000	68.7000	96.4000	125.2000
2012	91.6000	245.0000	112.3000	57.8000	14.5000	12.2000	19.2000	11.2000	37.9000	39.5000	74.7000	49.5000
2013	151.8000	145.5000	102.4000	12.5000	24.1000	13.2000	10.4000	44.3000	22.5000	94.6000	100.1000	182.0000
Precipitación mensual de la Estación Pluviométrica San Pedro de Cachi (mm)												
Año	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
2009	199.8000	166.5000	60.7000	53.1000	11.5000	0	20.6000	3.5000	11.9000	40.4000	107.0000	132.0000
2010	224.2000	99.9000	65.2000	36.4000	8.5000	0.5000	3.2000	11.8000	20.9000	33.2000	43.8000	152.4000
2011	187.4000	222.3000	157.8000	109.0000	4.3000	0	11.3000	0.9000	21.3000	53.2000	56.3000	113.1000
2012	84.7000	191.1000	96.3000	61.2000	28.9000	17.3000	12.0000	5.6000	27.1000	32.9000	34.8000	144.1000
2013	145.8000	102.3000	0	8.7000	47.3000	8.2000	0	44.3000	13.2000	37.7400	52.2600	128.4800

**Fuente:** Elaboración Propia.

### 7.3.1.4. Comparación Gráfica de Series Temporales del algoritmo 3B43 V7 del TRMM y SENAMHI


Previo al procedimiento del análisis y diseño de la Red Neuronal utilizando MATLAB se muestra en la figura 7.3 una gráfica comparativa de las series temporales relacionadas a las precipitaciones mensuales de la Estación Pluviométrica Huanta (SENAMHI) y Estación Sintética Huanta (TRMM). De la misma manera se muestran gráficos comparativos relacionados a las estaciones La Quinua y San Pedro de Cachi en las figuras 7.4 y 7.5 respectivamente. También se muestra una gráfica comparativa de series temporales para las tres estaciones pluviométricas en cuestión en la figura 7.6 y para las estaciones sintéticas en la figura 7.7.

Figura 7.3: Estación Huanta (TRMM y SENAMHI).




Fuente: Elaboración Propia.

Figura 7.4: Estación La Quinua (TRMM y SENAMHI).




Fuente: Elaboración Propia.

Figura 7.5: Estación San Pedro de Cachi (TRMM y SENAMHI).




Fuente: Elaboración Propia.

Figura 7.6: Estaciones Pluviométricas (SENAMHI).



Fuente: Elaboración Propia.

Figura 7.7: Estaciones Sintéticas (TRMM).



Fuente: Elaboración Propia.

La comparación gráfica se realiza aquí con el fin de observar el comportamiento de las precipitaciones (intensidad y tiempo en que suceden).

Cabe mencionar que las precipitaciones mensuales de las estaciones pluviométricas son el resultado de la acumulación de precipitaciones diarias obtenidas del SENAMHI y las precipitaciones mensuales del algoritmo 3B43 V7 del TRMM son el resultado de la acumulación de precipitaciones diarias del TRMM.

Las precipitaciones mensuales son usadas comúnmente en modelos hidrológicos planteados en investigaciones avanzadas sobre hidrología, para calcular la cantidad de precipitación caída sobre una determinada área, entre otros usos.

Es posible la extensión de las series temporales obtenidas al utilizar la Red Neural establecida en este estudio (Predicción) utilizando Redes Neuronales Dinámicas.

### 7.3.2. Procedimiento de diseño y análisis

#### 7.3.2.1. Matriz de Ingreso y Matriz Objetivo de la Red Neuronal

Las tres primeras columnas del cuadro 7.5 representan la matriz de ingreso<sup>4</sup> de la Red Neuronal y la última columna representa la matriz objetivo<sup>5</sup> de la Red Neuronal.

**Cuadro 7.5:** Matriz de Ingreso y Objetivo de la Red.

Matriz de Ingreso			Matriz Objetivo
1	2009	113.9830	91.9000
2	2009	172.3130	120.6000
3	2009	114.4070	71.9000
4	2009	104.0990	48.8000
5	2009	37.6143	29.9000
6	2009	10.1245	1.1000
7	2009	16.6350	10.3000
Continúa en la siguiente página			

<sup>4</sup>Para el ingreso a la Red Neuronal se requiere que la matriz de ingreso tenga el orden de 3 x 180.

<sup>5</sup>Para el ingreso a la Red Neuronal se requiere que la matriz objetivo tenga el orden de 1 x 180.

**Cuadro 7.5 – Continúa de la página anterior**

Matriz de Ingreso			Matriz Objetivo
8	2009	52.3879	7.5000
9	2009	40.6523	10.2000
10	2009	63.9543	17.2000
11	2009	60.9438	33.7000
12	2009	92.2513	49.4000
1	2010	155.5940	163.4000
2	2010	75.9840	61.1000
3	2010	140.8390	92.3000
4	2010	54.1633	22.1000
5	2010	44.3207	0.0000
6	2010	8.0093	0.0000
7	2010	21.1814	0.0000
8	2010	38.9831	4.0000
9	2010	34.8467	7.0000
10	2010	86.5043	40.8000
11	2010	44.9477	29.4000
12	2010	103.7980	137.9000
1	2011	131.3240	208.8000
2	2011	160.4510	93.1000
3	2011	234.4430	78.3000
4	2011	84.5714	29.5000
5	2011	38.7978	7.6000
6	2011	1.6459	0.2000
7	2011	31.1045	1.3000
8	2011	16.0016	0.2000
9	2011	45.3819	13.9000
10	2011	57.4980	35.6000
11	2011	113.9980	58.6000
12	2011	148.0290	92.0000
1	2012	135.2180	89.9000
2	2012	172.7160	139.5000
3	2012	118.2520	38.6000
4	2012	69.9031	58.3000

Continúa en la siguiente página

**Cuadro 7.5 – Continúa de la página anterior**

Matriz de Ingreso			Matriz Objetivo
5	2012	14.6823	8.3000
6	2012	15.9119	5.7000
7	2012	22.8793	6.3000
8	2012	43.6476	6.2000
9	2012	73.4892	21.5000
10	2012	64.9423	21.6000
11	2012	82.2880	37.3000
12	2012	149.0470	130.9000
1	2013	107.9640	132.1000
2	2013	129.9560	98.0000
3	2013	97.4443	76.9000
4	2013	48.4168	34.7000
5	2013	21.4857	0.0000
6	2013	8.8660	1.6000
7	2013	30.1145	1.3000
8	2013	44.45430	39.2000
9	2013	71.8208	2.4000
10	2013	73.9590	27.1400
11	2013	82.2263	36.8600
12	2013	137.9450	89.5600
1	2009	121.5410	150.5000
2	2009	149.7970	174.8000
3	2009	101.4770	59.5000
4	2009	75.3891	55.9000
5	2009	35.0727	26.7000
6	2009	0.6329	0.4000
7	2009	17.6206	5.0000
8	2009	24.1954	8.7000
9	2009	17.8437	36.7000
10	2009	51.1599	50.6000
11	2009	59.6677	113.7000
12	2009	134.5720	109.9000
1	2010	171.9470	138.7000

Continúa en la siguiente página

**Cuadro 7.5 – Continúa de la página anterior**

<b>Matriz de Ingreso</b>			<b>Matriz Objetivo</b>
2	2010	86.8840	120.2000
3	2010	101.9430	124.8000
4	2010	32.3946	23.0000
5	2010	20.5647	8.6000
6	2010	0.3712	0.0000
7	2010	8.6787	6.6000
8	2010	17.4365	15.0000
9	2010	29.9609	17.3000
10	2010	59.7806	91.2000
11	2010	36.4349	33.9000
12	2010	103.4350	132.9000
1	2011	163.1500	188.9000
2	2011	194.8160	203.8000
3	2011	237.8900	170.4000
4	2011	57.5143	61.6000
5	2011	22.0260	17.3000
6	2011	1.8743	5.6000
7	2011	25.7613	6.6000
8	2011	10.7689	5.2000
9	2011	40.7528	67.7000
10	2011	55.4625	68.7000
11	2011	102.5450	96.4000
12	2011	142.5610	125.2000
1	2012	135.0490	91.6000
2	2012	183.3930	245.0000
3	2012	124.8770	112.3000
4	2012	56.9612	57.8000
5	2012	15.9437	14.5000
6	2012	6.5833	12.2000
7	2012	15.6615	19.2000
8	2012	19.1798	11.2000
9	2012	54.9732	37.9000
10	2012	46.1977	39.5000
Continúa en la siguiente página			

**Cuadro 7.5 – Continúa de la página anterior**

Matriz de Ingreso			Matriz Objetivo
11	2012	84.2224	74.7000
12	2012	161.0510	49.5000
1	2013	100.7590	151.8000
2	2013	137.5280	145.5000
3	2013	139.5270	102.4000
4	2013	33.4409	12.5000
5	2013	21.8446	24.1000
6	2013	7.4635	13.2000
7	2013	20.0796	10.4000
8	2013	26.8259	44.3000
9	2013	32.9407	22.5000
10	2013	80.9127	94.6000
11	2013	81.4774	100.1000
12	2013	152.2050	182.0000
1	2009	122.3420	199.8000
2	2009	134.9640	166.5000
3	2009	74.6208	60.7000
4	2009	64.1177	53.1000
5	2009	31.1638	11.5000
6	2009	4.3385	0.0000
7	2009	19.9760	20.6000
8	2009	21.0657	3.5000
9	2009	14.3045	11.9000
10	2009	46.1277	40.4000
11	2009	53.4620	107.0000
12	2009	119.7820	132.0000
1	2010	203.2880	224.2000
2	2010	85.8590	99.9000
3	2010	99.0827	65.2000
4	2010	35.0612	36.4000
5	2010	20.3236	8.5000
6	2010	0.0402	0.5000
7	2010	1.9940	3.2000
Continúa en la siguiente página			

**Cuadro 7.5 – Continúa de la página anterior**

Matriz de Ingreso			Matriz Objetivo
8	2010	17.5798	11.8000
9	2010	24.4064	20.9000
10	2010	54.8699	33.2000
11	2010	25.2692	43.8000
12	2010	88.3064	152.8000
1	2011	161.9170	187.4000
2	2011	176.0780	222.3000
3	2011	242.3460	157.8000
4	2011	55.5447	109.0000
5	2011	19.9273	4.3000
6	2011	0.7910	0.0000
7	2011	25.3646	11.3000
8	2011	10.9906	0.9000
9	2011	38.8448	21.3000
10	2011	49.7570	53.2000
11	2011	78.1859	56.3000
12	2011	131.7980	113.1000
1	2012	140.5550	84.7000
2	2012	166.7690	191.1000
3	2012	122.7550	96.3000
4	2012	58.5693	61.2000
5	2012	17.8688	28.9000
6	2012	5.2663	17.3000
7	2012	13.8485	12.0000
8	2012	14.5393	5.6000
9	2012	54.7764	27.1000
10	2012	30.4864	32.9000
11	2012	64.3260	34.8000
12	2012	139.9590	144.1000
1	2013	105.0920	145.8000
2	2013	141.7630	102.3000
3	2013	90.7801	0.0000
4	2013	29.2451	8.7000
Continúa en la siguiente página			

**Cuadro 7.5 – Continúa de la página anterior**

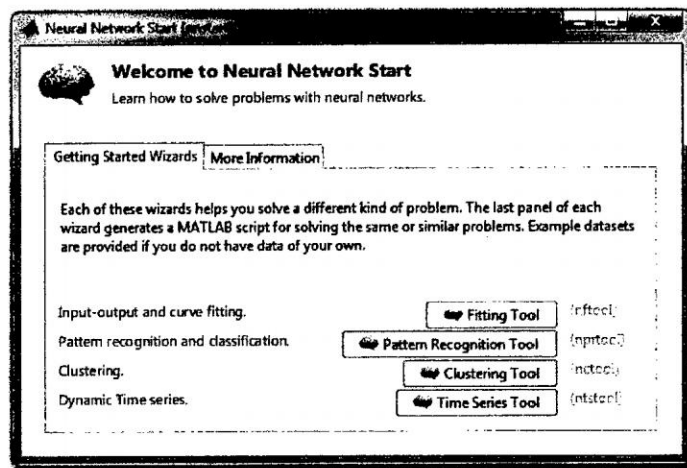
Matriz de Ingreso			Matriz Objetivo
5	2013	15.7634	47.3000
6	2013	15.9513	8.2000
7	2013	10.1121	0.0000
8	2013	22.6594	44.3000
9	2013	30.5166	13.2000
10	2013	64.6093	37.7400
11	2013	65.1074	52.2600
12	2013	182.0600	128.4800

**Fuente:** Elaboración Propia.

### 7.3.2.2. Procedimiento de acuerdo a MATLAB

Para este estudio se emplea la caja de herramientas de Redes Neuronales de MATLAB que al iniciar nos muestra la figura 7.8 donde elegimos la opción Fitting Tool; luego nos muestra una ventana (ver figura 7.9) que utiliza una red feed forward con la función de transferencia tan-sigmoid por defecto en la capa oculta y la función de transferencia lineal en la capa de salida. Esta estructura es útil para problemas de aproximación de funciones. El paso de configuración se realiza estableciendo parámetros para la red neuronal que son mostrados en el cuadro 7.6.

**Figura 7.8:** Ventana de inicio de Red Neuronal.



**Fuente:** Matlab 2014a.

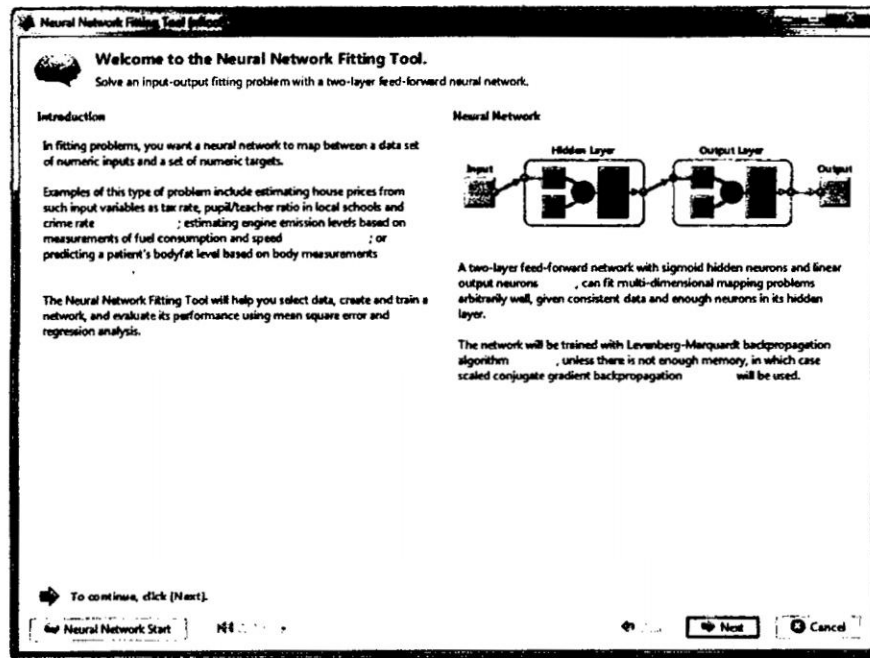
**Cuadro 7.6:** Funciones para dividir datos.

Parámetros establecidos de la Red Neuronal	
Funciones de procesamiento de la capa oculta	removeconstantrows y mapminmax
Funciones de procesamiento de la capa de salida	removeconstantrows y mapminmax
Función de división	dividerand
Algoritmo de entrenamiento	Levenberg-Marquardt
Porcentaje del subconjunto de entrenamiento	90 %
Porcentaje del subconjunto de validación	5 %
Porcentaje del subconjunto de prueba	5 %

**Fuente:** Elaboración Propia.

Al continuar con el uso de la Caja de Herramientas de MATLAB se establece una breve introducción al ajuste de funciones y explicación de la Red Neuronal utilizada, tal como se muestra en la figura 7.9.

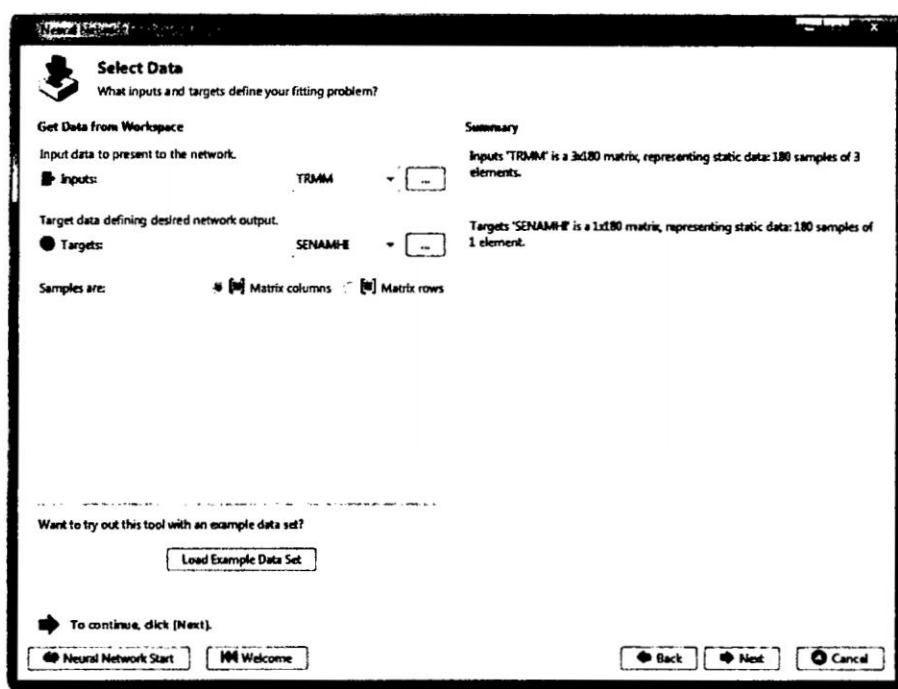
**Figura 7.9:** Ventana de Red Neuronal para ajuste.



**Fuente:** Matlab 2014a.

En la ventana relacionada a la selección de datos se establece la matriz de ingreso y la matriz objetivo para la Red Neuronal de acuerdo a matrices establecidas previamente con los nombres TRMM y SENAMHI, tal como se muestra en la figura 7.10.

Figura 7.10: Ventana de selección de ingresos y objetivos de Red Neuronal.



Fuente: Matlab 2014a.

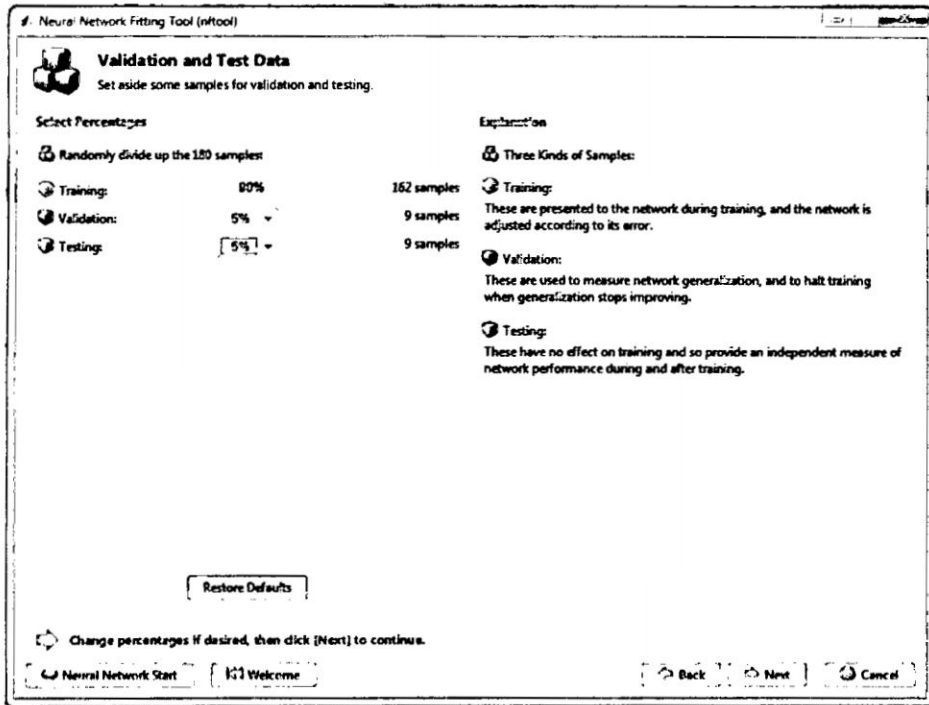
Luego la aplicación divide de manera aleatoria matrices de entrada y matrices objetivo en tres subconjuntos de acuerdo al porcentaje establecido en la figura 7.11 de la siguiente manera:

- 90 % usado para entrenamiento.
- 5 % se utiliza para validar que la red está generalizando y para detener la formación antes del sobreajuste.
- el último 5 % se utiliza como una prueba totalmente independiente de la generalización de la red.

Después de innumerables entrenamientos de la Red Neuronal se determinó que el número de neuronas en la capa oculta debe ser 120; la red tiene sólo una neurona de salida, porque sólo hay un valor de destino asociada a la matriz de entrada. La arquitectura de la Red Neuronal se establece en la figura 7.12.

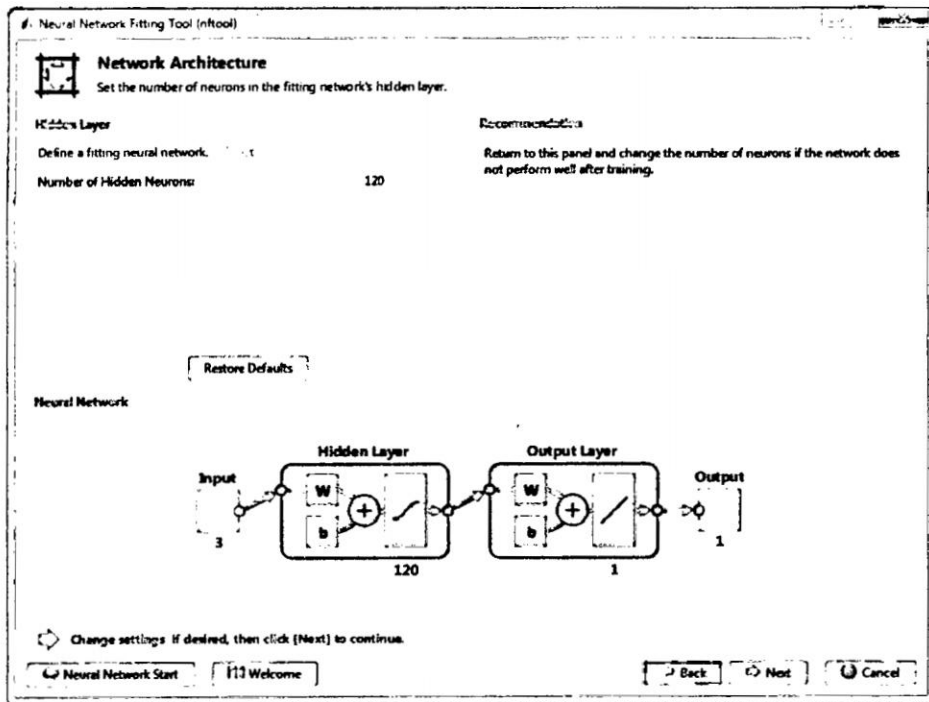
Aplicaciones de Redes Neuronales que automatizan el entrenamiento de su Red Neuronal para ajustar los datos de entrada y objetivo se muestran en la figura 7.13.

Figura 7.11: Ventana de división de datos de ingreso de Red Neuronal.



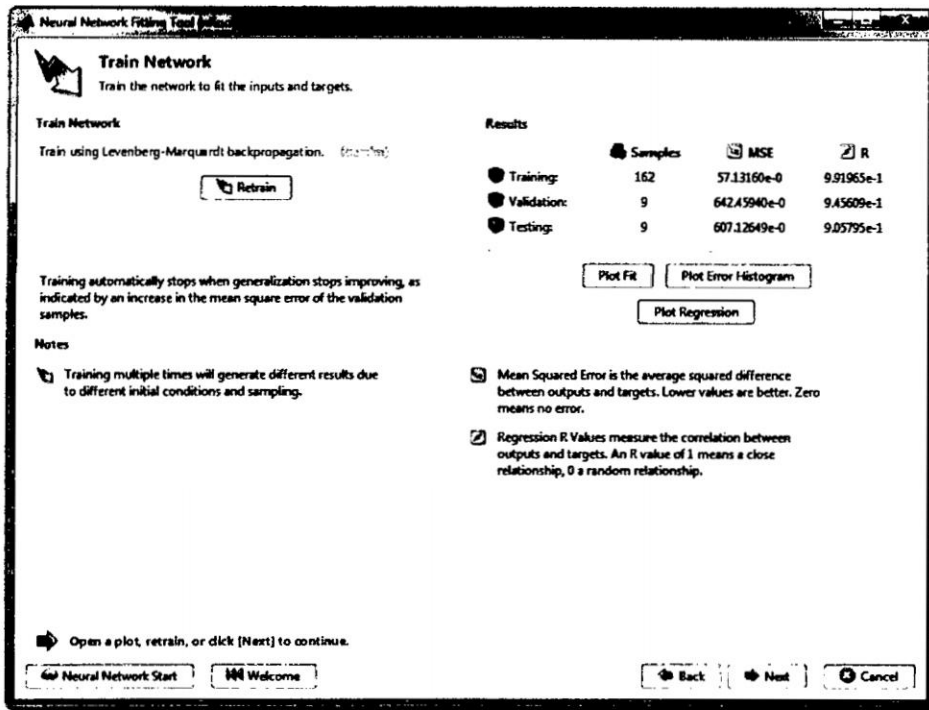
Fuente: Matlab 2014a.

Figura 7.12: Arquitectura de la Red Neuronal.



Fuente: Matlab 2014a.

Figura 7.13: Ventana de entrenamiento de la Red Neuronal.



Fuente: Matlab 2014a.

De la misma manera aplicaciones para supervisar el progreso del entrenamiento y calcular resultados estadísticos y gráficos para evaluar la calidad del entrenamiento se muestran en la figura 7.14. Además le permite interrumpir el entrenamiento en cualquier momento haciendo clic en Stop Training.

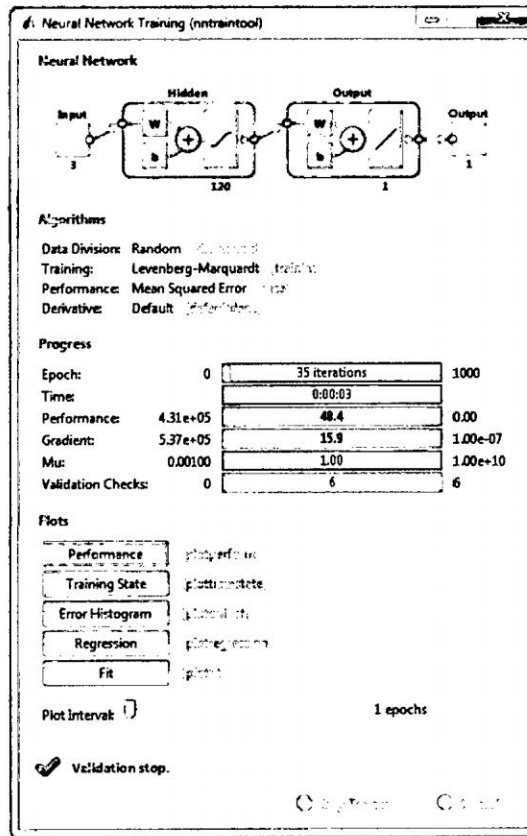
Esta formación se detuvo cuando aumenta el error de validación durante seis iteraciones, que se produjo en la iteración 35 (ver figura 7.15).

Para encontrar el error de validación, hacer click en Performance en la ventana de supervisión del progreso del entrenamiento de Red Neuronal (ver figura 7.14), Un trazo de los errores de entrenamiento, errores de validación, y errores de prueba aparece, como se muestra en la figura 7.15. El mejor rendimiento de validación se produjo en la iteración 29 (donde se produce el mejor rendimiento de validación).

En esta aplicación, el resultado es razonable debido a las siguientes consideraciones:


- El error medio cuadrático final es pequeño.

Figura 7.14: Ventana de supervisión del progreso del entrenamiento de Red Neuronal.



Fuente: Matlab 2014a.

Figura 7.15: Ventana de errores de entrenamiento, validación y prueba de Red Neuronal.



Fuente: Matlab 2014a.

- El error del subconjunto de prueba y el error del subconjunto de validación establecidos tienen características similares.
- Sobreajuste no significativo se ha producido en la iteración 29 (donde se produce el mejor rendimiento de validación).

Si hace clic en Regression en la ventana de supervisión del progreso del entrenamiento de Red Neuronal (ver figura 7.14), se puede realizar una regresión lineal entre las salidas de la red y los objetivos correspondientes. La figura 7.16 muestra los resultados. Idealmente (con error zero) los puntos deberían ser colocados en la línea objetivo igual a la línea de salida. En nuestro caso, la salida del seguimiento de los objetivos está muy bien para los subconjuntos de entrenamiento, prueba y validación; y el valor R (coeficiente de correlación) es un poco más de 0,98 para la respuesta total.

Si se requiere resultados más precisos, puede probar cualquiera de estos enfoques

- Reestablecer los pesos y umbrales iniciales de la red y entrenar de nuevo.
- Incrementar el número de neuronas en la capa oculta.
- Incrementar el número de vectores de entrenamiento (más datos).
- Incrementar el número de valores de ingreso, si información más relevante es permitible.
- Probar con diferentes algoritmos de entrenamiento.

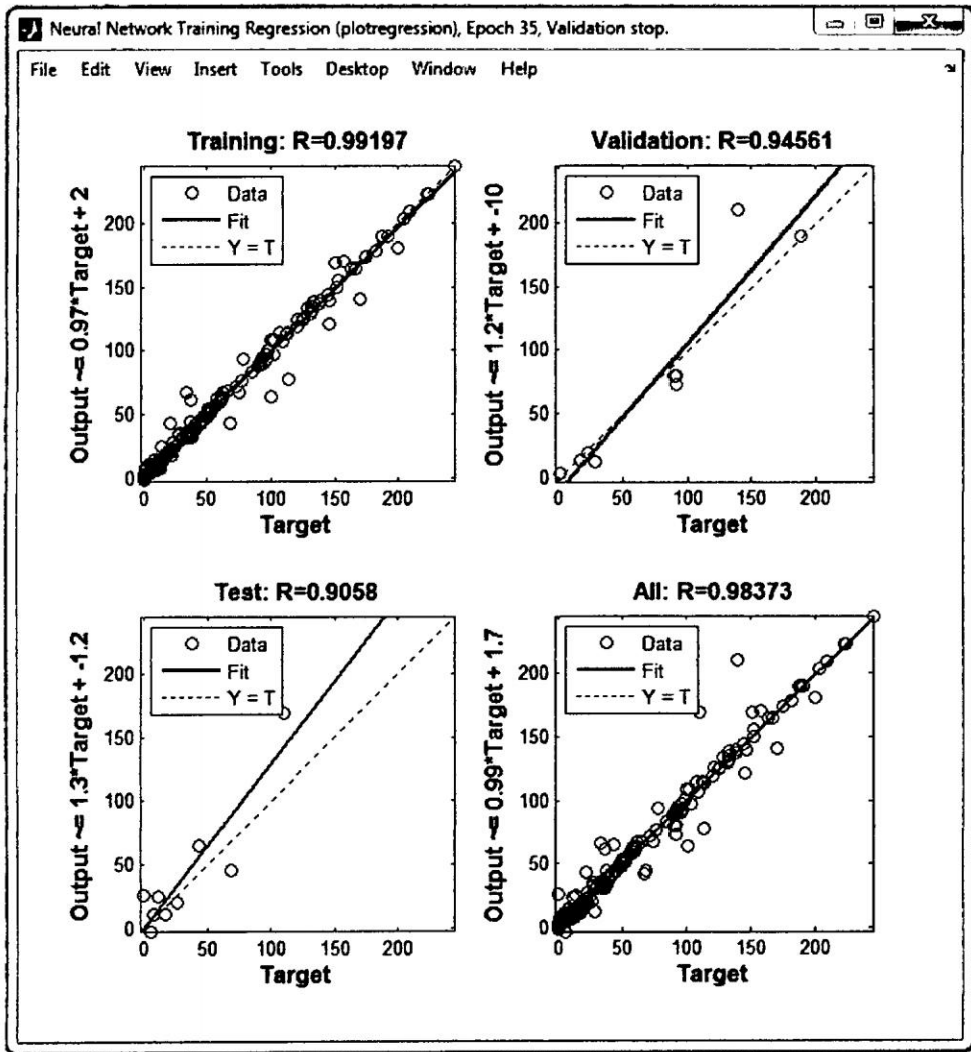
En este caso, la respuesta de la red es satisfactoria y por lo tanto, es considerada la Red Neuronal para el presente estudio de validación.<sup>6</sup>

Finalmente el funcionamiento de la Red Neuronal establecida en el presente estudio se muestra en la parte V de este estudio, donde además se muestran valores tabulados de los parámetros (pesos y umbrales) de la Red Neuronal.

---

<sup>6</sup>En necesario mencionar que la Red Neuronal establecida en el presente estudio no es la más óptima, pero si es una Red Neuronal que soluciona el problema planteado en el presente estudio.

Figura 7.16: Ventana de regresión lineal de la Red Neuronal.



Fuente: Matlab 2014a.

## Parte IV

# Resultados

# Capítulo 8

## Resultados y Discuciones

En este capítulo se realiza en primer lugar las comparaciones entre las precipitaciones obtenidas in situ y a partir del TRMM a escala diaria, mensual, estacional, anual y de largo plazo.

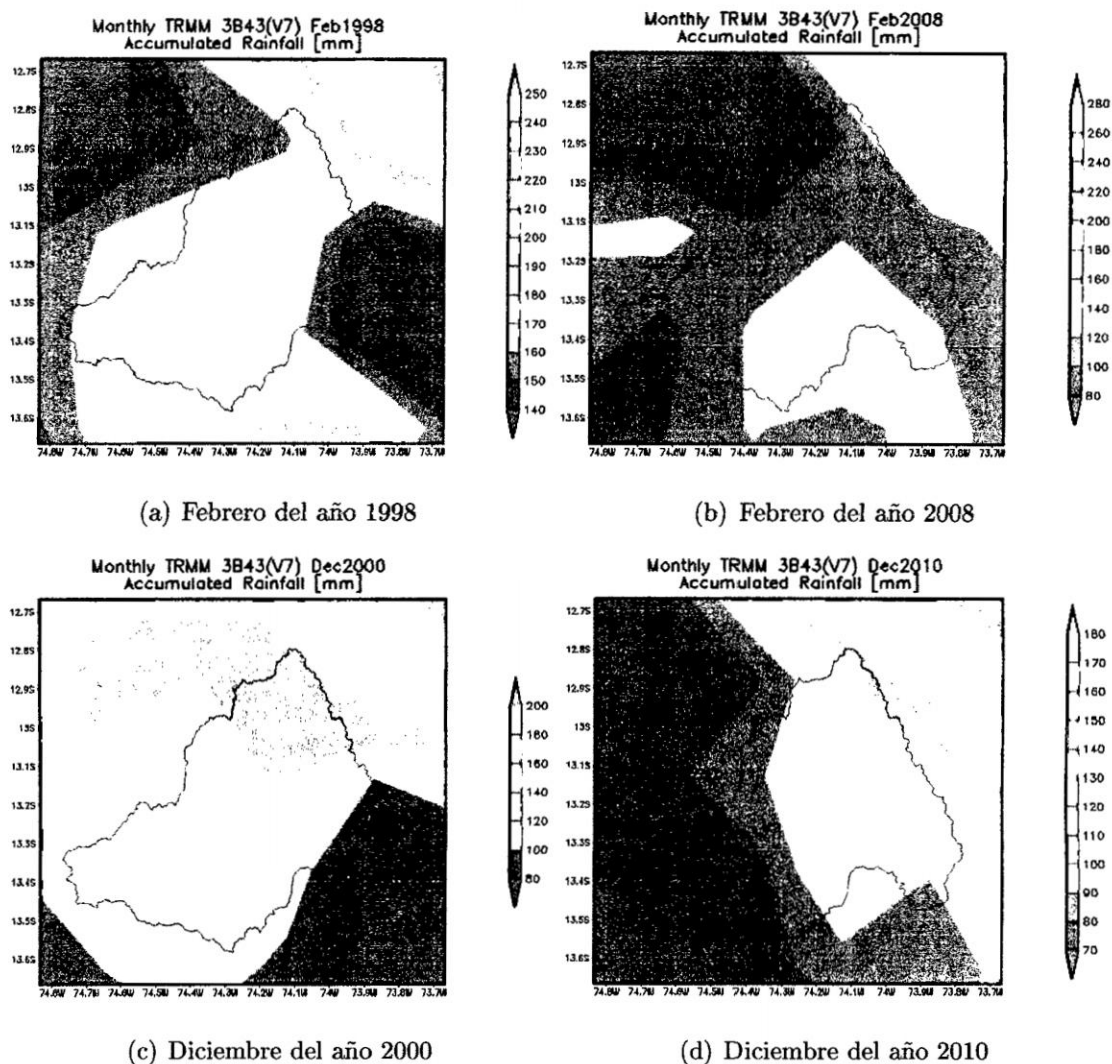
### **8.1. Distribución de precipitaciones mensuales sobre la Cuenca del Río Cachi como se observa a partir del TRMM**

La medición de la distribución espacial de las precipitaciones en una región montañosa como la Cuenca del Río Cachi es muy difícil, debido a muchas limitaciones incluyendo la configuración y mantenimiento de la red de pluviómetros. Los datos del TRMM pueden proporcionar una mejor distribución de las lluvias sobre la Cuenca del Río Cachi, ya que observa desde la parte superior y cubre un área amplia. El TRMM 3B43 (V7) proporciona precipitaciones acumuladas mensuales. La figura 8.1 muestra las precipitaciones mensuales para el mes de febrero de los años 1998 y 2008; además de mostrar precipitaciones mensuales para el mes de diciembre de los años 2000 y 2010. <sup>1</sup>

---

<sup>1</sup>Esta gráficas la realiza la página web del TRMM <http://pmm.nasa.gov/TRMM> mediante el procedimiento de extrapolación lineal.

**Figura 8.1:** Distribución espacial de precipitaciones mensuales sobre la Cuenca del Río Cachi.



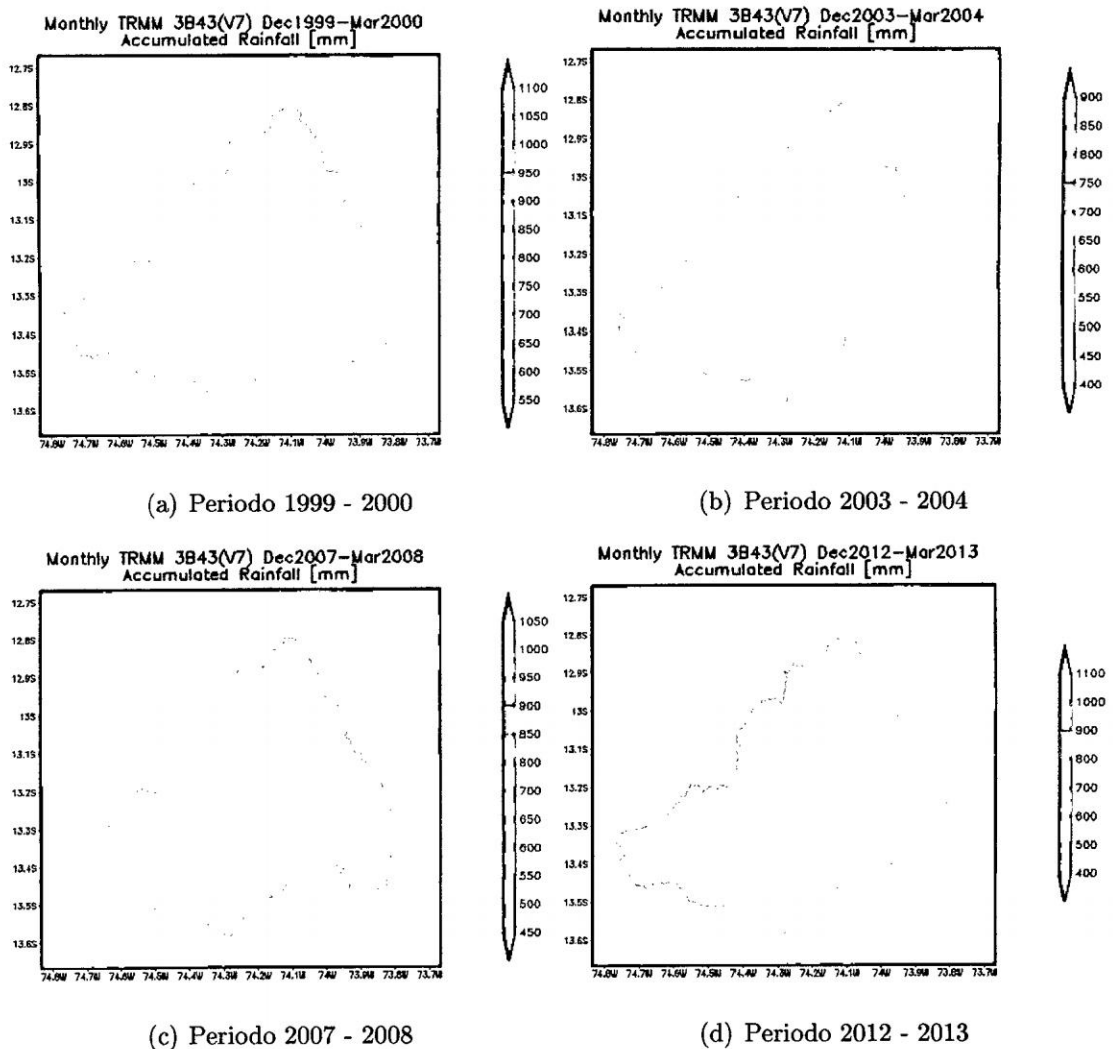
**Fuente:** Tropical Rainfall Measuring Mission (TRMM)-NASA.

Según la estación climatológica de Huamanga, representativa para la zona de estudio, se tiene una temperatura del aire media mensual de 15.4°C con medias máximas de 25.3°C en noviembre y medias mínimas de 4.7°C en julio habiendo un periodo frío de Mayo a Agosto y un periodo caliente de Septiembre a Abril. Usualmente lluvia muy ligera sobre la Cuenca del Río Cachi es observada durante los meses de Abril, Septiembre, Octubre y Noviembre. La precipitación es apenas observada entre los meses de Mayo y Agosto. La mayor parte de la precipitación anual se produce durante los meses de Diciembre a Marzo.

## 8.2. Distribución de precipitaciones estacionales sobre la Cuenca del Río Cachi como se observa a partir del TRMM

Como se mencionó en la sección anterior, la mayor parte de la precipitación se produce durante los meses de diciembre a Marzo. La distribución espacial de las precipitaciones acumuladas para tales periodos son presentadas aleatoriamente en la figura 8.2.

**Figura 8.2:** Distribución espacial de precipitaciones estacionales sobre la Cuenca del Río Cachi.

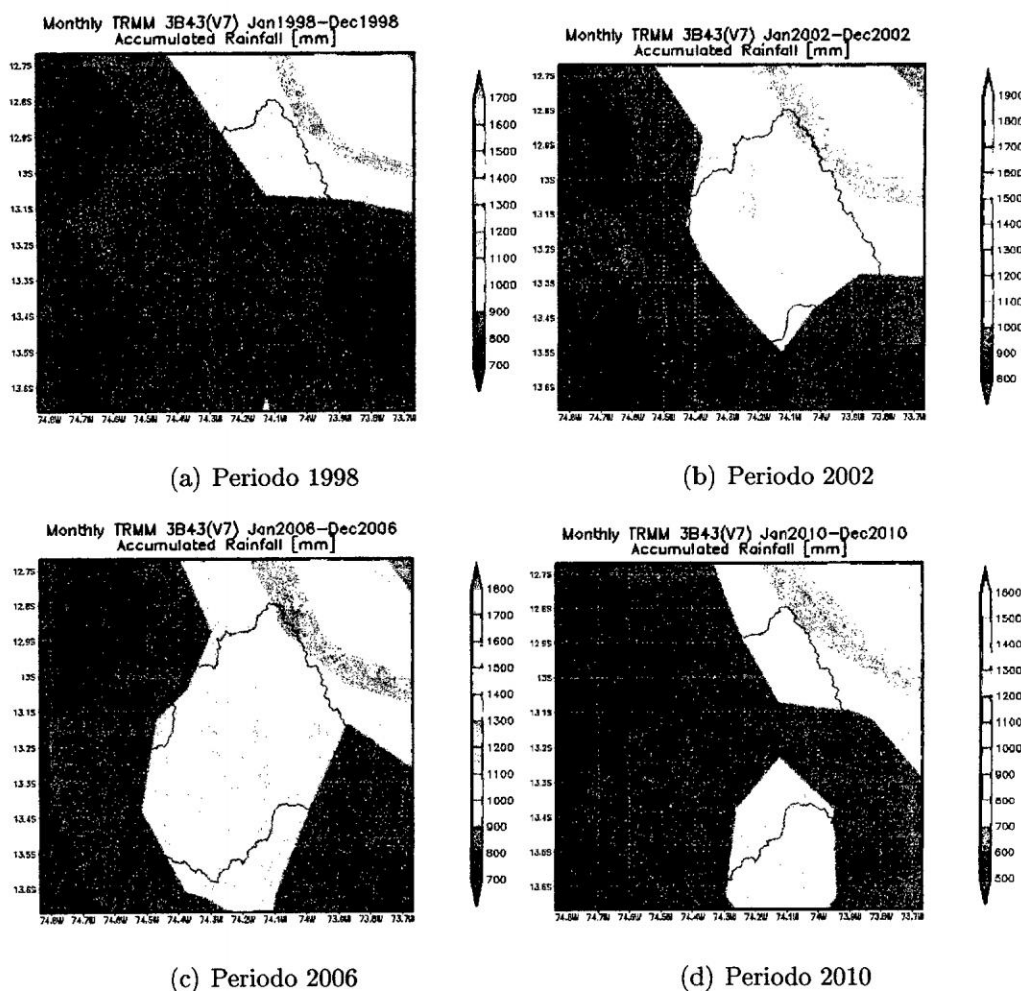


**Fuente:** Tropical Rainfall Measuring Mission (TRMM)-NASA.

### 8.3. Distribución de precipitaciones anuales sobre la Cuenca del Río Cachi como se observa a partir del TRMM

Precipitaciones anuales se muestran aleatoriamente en la figura 8.3. Aquí se muestra que la precipitación va decreciendo de izquierda a derecha; es decir de zonas cercanas a la Costa a zonas cercanas a la Selva; resultado que es coherente respecto a las precipitaciones que observamos en el Perú, el cual nos indican escasa precipitación en las Costa y abundante precipitación en la Selva.

**Figura 8.3:** Distribución espacial de precipitaciones anuales sobre la Cuenca del Río Cachi.



Fuente: Tropical Rainfall Measuring Mission (TRMM)-NASA.

## 8.4. Comparación de precipitación día a día

Para obtener comparaciones de las precipitaciones obtenidas día a día del TRMM y pluviómetros en estaciones individuales, éstas se eligen de las estaciones pluviométricas involucradas en este estudio.

Haciendo un análisis en conjunto para evitar redundancia, se puede observar en cada uno de los gráficos comparativos días en los cuales el TRMM subestima y sobreestima la precipitación in situ, observándose una tendencia ligeramente similar pero no igual.<sup>2</sup>

Diversos estudios de validación de la precipitación derivada del TRMM como el realizado por Islam (Referencia [14]), realizan análisis estadísticos para determinar los porcentajes de subestimación y sobreestimación de precipitaciones derivadas del TRMM. En esta tesis se hace mayor énfasis al empleo de Redes de Neuronas Artificiales para la validación, razón por la cual no se realiza dicho análisis estadístico.

Las diversas gráficas comparativas de series temporales son realizadas usando MATLAB debido a su gran potencial para poder personalizar la salida.

Las figuras 8.6, 8.7, 8.8, 8.9, 8.10, 8.11, 8.12, 8.13 y 8.14 muestran las gráficas comparativas de precipitaciones diarias para las estaciones involucradas en este estudio.

Resultados similares se muestran para Nepal en el estudio realizado por Islam (Referencia [14]), donde se puede observar gráficos comparativos con resultados similares a los obtenidos sobre la Cuenca del Río Cachi por razones que expondremos en la parte V de este estudio.

Debido a que todavía existe diferencias (subestimaciones y sobreestimaciones) a nivel diario, este estudio de validación no se realiza teniendo en cuenta precipitaciones diarias.

A partir del año 2014 la NASA y JAXA han lanzado la Misión de la Medición

---

<sup>2</sup>Alta incertidumbre de detección de lluvia ligera, todavía existe en la precipitación diaria del TRMM, que conduce a diferentes errores: sobreestimaciones, falsas alarmas y omisiones en la detección.

de la Precipitación Global (GPM)<sup>3</sup> que espera superar misiones anteriores y con lo cual podría obtenerse mejores resultados en cuanto a la precipitación diaria.

## 8.5. Comparación de precipitación mes a mes

Como se detalló anteriormente las precipitaciones a nivel mensual son las que mejor similaridad tienen. Aquí se muestran gráficos comparativos de series temporales a una escala mensual para las estaciones involucradas en este estudio.

En estas gráficas intervienen precipitaciones in situ (SENAMHI), precipitaciones derivadas del TRMM 3B43 V7 y precipitaciones provenientes de la salida de Red Neuronal.

Los resultados nos indican un buen ajuste en lo referente a precipitaciones involucradas en el establecimiento de los parámetros de la Red Neuronal (Pesos y Umbrales).<sup>4</sup>

Las figuras 8.15, 8.16 y 8.17 muestran las gráficas comparativas de precipitaciones mensuales para las estaciones involucradas en el establecimiento de la Red Neuronal.

## 8.6. Salida de la Red Neuronal a otras estaciones

Como se planteó anteriormente, el objetivo central de este estudio es obtener salidas de una Red Neuronal que sean semejantes a las mediciones in situ de las precipitaciones sobre la Cuenca del Río Cachi; tanto para estaciones involucradas en este estudio, así como para ubicaciones sobre la Cuenca del río Cachi que no cuentan con referencia alguna de datos precipitación.

En el Perú las medidas de las variables hidrometeorológicas están a cargo del Ser-

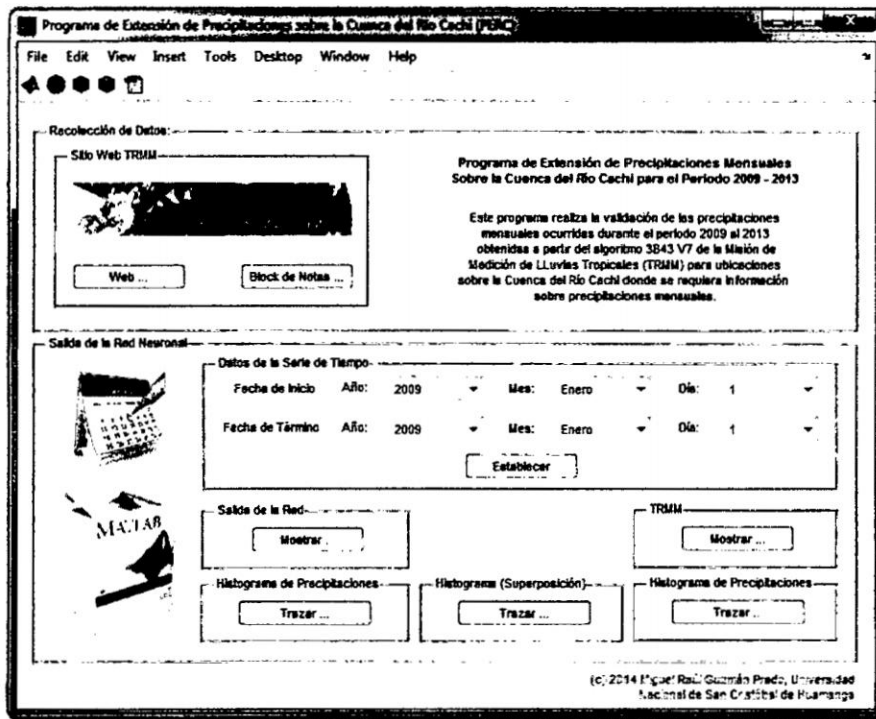
---

<sup>3</sup>La página web de la Misión de la Medición de la Precipitación Global es <http://pmm.nasa.gov/GPM>

<sup>4</sup>Se debe tener en cuenta que la Red Neuronal establecida en el presente estudio fue obtenida luego de innumerables entrenamientos, obteniéndose así una Red Neuronal que pueda que no sea la más óptima pero si una red que nos resuelve el problema de ajuste planteado.

vicio Nacional de Meteorología e Hidrología, SENAMHI<sup>5</sup>. La mayoría de los datos hidrometeorológicos están relacionados a variables climáticas (lluvia, temperatura, etc.). Las estaciones pluviométricas sobre la Cuenca del Río Cachi están pobremente distribuidas. Precipitaciones derivadas del producto 3B43 V7 del TRMM han sido usadas con buenos resultados sobre distintas partes del mundo como por ejemplo en las referencias [14] y [7], quienes comparan o mejoran los valores in situ de precipitaciones observadas.

Figura 8.4: Ventana principal del programa PERC.



Fuente: Elaboración Propia.

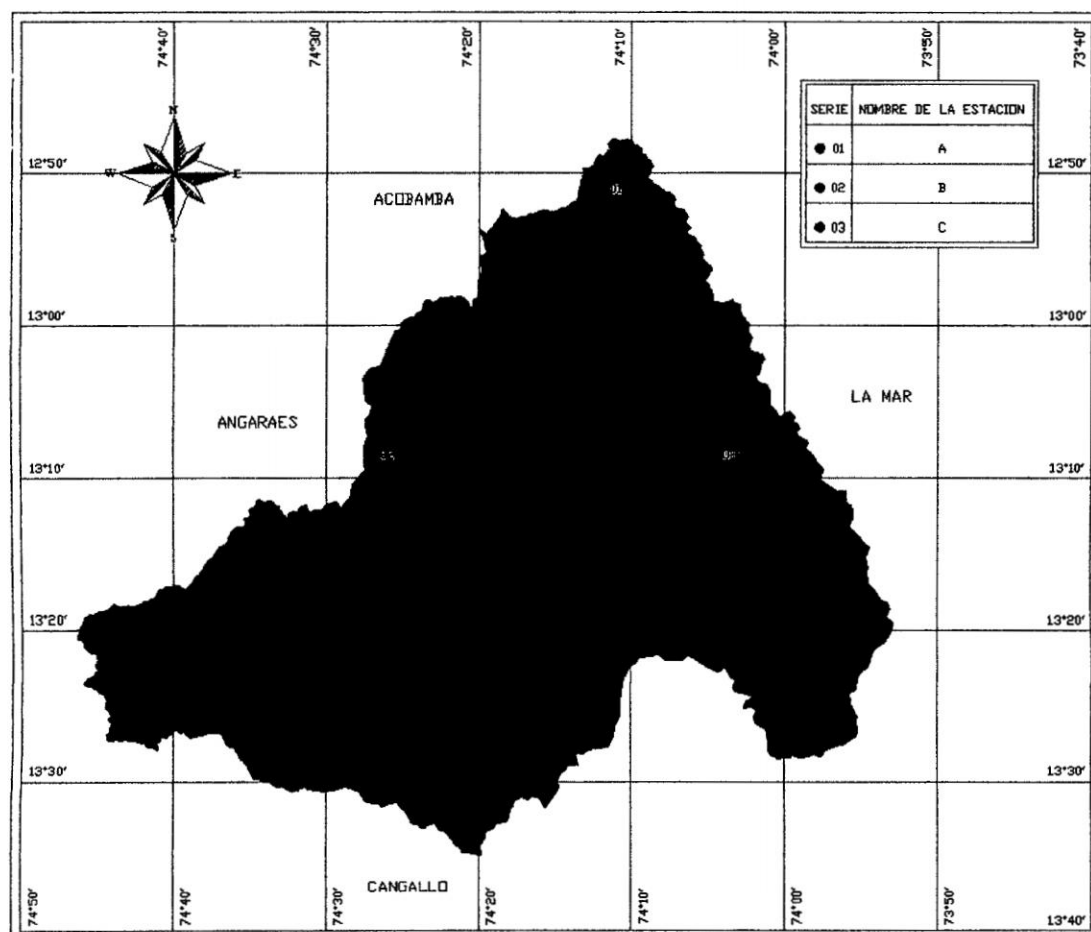
Luego de establecer la Red Neuronal se puede obtener salidas de la Red Neuronal. Para lo cual se ha creado un programa en MATLAB que realice este procedimiento y nos muestre valores tabulados y gráficos; en donde se muestran precipitaciones derivadas del TRMM y de la Salida de la Red, los cuales deben mantener cierta similitud de acuerdo a lo observado en gráficas comparativas anteriores al esta-

<sup>5</sup>La página web del SENAMHI es <http://www.senamhi.gob.pe/>.

blecimiento de la Red Neuronal.<sup>6</sup>

La ventana principal del programa se muestra en la figura 8.4 y las ubicaciones de las estaciones de las cuales se quiere conocer sus precipitaciones in situ se muestran en la figura 8.5.

**Figura 8.5:** Ubicación de estaciones no involucradas en este estudio sobre la Cuenca del Río Cachi.



**Fuente:** Elaboración Propia.

Las coordenadas geográficas (latitud y longitud) de las estaciones no involucradas en el establecimiento de la Red Neuronal (ver figura 8.5) se muestran en el cuadro 8.1 para su ingreso en el programa PERC elaborado en MATLAB, el cual requiere

<sup>6</sup>La descripción de las componentes y uso del programa PERC se encuentran en el anexo B, donde se puede encontrar la manera en que se recolectan datos a partir del TRMM y el procedimiento hasta obtener la salida de la Red Neuronal establecida en este estudio.

al ingresar en la página web del TRMM<sup>7</sup> coordenadas geográficas para la obtención de datos de ingreso para la Red Neuronal establecida en el presente estudio.

**Cuadro 8.1:** Series, Nombres y Coordenadas Geográficas de las estaciones no involucradas en este estudio.

Serie	Nombre de la Estación	Latitud (Grados)	Longitud (Grados)
01	Estación A	12°50'00"S	74°10'00"W
02	Estación B	13°7.5'00"S	74°25'00"W
03	Estación C	13°7.5'00"S	74°2.5'00"W

**Fuente:** Elaboración Propia.

Las salidas de la Red Neuronal a las estaciones no involucradas en este estudio se muestran en las figuras 8.18, 8.19, 8.20, que muestran una cierta similitud en comparación a las precipitaciones derivadas del algoritmo TRMM 3B43 V7.


Cabe mencionar que la Salida de la Red a estaciones ubicadas más al sur de la Cuenca del Río Cachi carecen de similitud respecto a las precipitaciones derivadas del TRMM.

Datos del algoritmo 3B43 V7 del TRMM y su mejoramiento (Salida de la Red Neuronal) se comportan como los mejores para describir los regímenes hidrológicos sobre regiones con pobre distribución de estaciones pluviométricas en la Cuenca del Río Cachi, pero estaciones pluviométricas son indispensables para validar y mejorar los datos de lluvia. Futuros trabajos en esta Cuenca se centraran en mejorar los datos TRMM a nivel diario usando información observada así como modelos hidrológicos a paso de tiempo diario.

---


<sup>7</sup>La página web donde se pueden obtener datos del algoritmo 3B43 V7 del TRMM (Misión de medición de lluvias tropicales) es [http://disc2.nascom.nasa.gov/Giovanni/tovas/TRMM\\_V7.3B43.2.shtml](http://disc2.nascom.nasa.gov/Giovanni/tovas/TRMM_V7.3B43.2.shtml).

Figura 8.6: Precipitación diaria de la Estación Alpachaca (2004).




Fuente: Elaboración Propia.

Figura 8.7: Precipitación diaria de la Estación Alpachaca (2007).




Fuente: Elaboración Propia.

Figura 8.8: Precipitación diaria de la Estación La Quinua (2009).




Fuente: Elaboración Propia.

Figura 8.9: Precipitación diaria de la Estación La Quinua (2012).




Fuente: Elaboración Propia.

Figura 8.10: Precipitación diaria de la Estación Wayllapampa (2009).




Fuente: Elaboración Propia.

Figura 8.11: Precipitación diaria de la Estación Wayllapampa (2012).




Fuente: Elaboración Propia.

Figura 8.12: Precipitación diaria de la Estación Huanta (2009).




Fuente: Elaboración Propia.

Figura 8.13: Precipitación diaria de la Estación San Pedro de Cachi (2012).




Fuente: Elaboración Propia.

Figura 8.14: Precipitación diaria de la Estación Huamanga(2008).




Fuente: Elaboración Propia.

Figura 8.15: Precipitaciones mensuales de la estación Huanta.




Fuente: Elaboración Propia.

Figura 8.16: Precipitaciones mensuales de la estación La Quinua.




Fuente: Elaboración Propia.

Figura 8.17: Precipitaciones mensuales de la estación San Pedro de Cachi.




Fuente: Elaboración Propia.

Figura 8.18: Salida de la Red Neuronal para la Estación A.



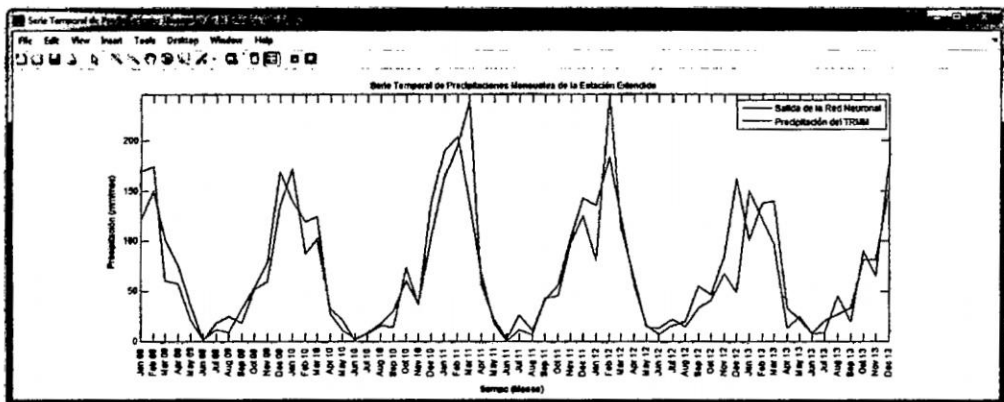
Fuente: Elaboración Propia.

Figura 8.19: Salida de la Red Neuronal para la Estación B.



Fuente: Elaboración Propia.

Figura 8.20: Salida de la Red Neuronal para la Estación C.



Fuente: Elaboración Propia.

## Parte V

# Conclusiones

# Capítulo 9

## Conclusiones, Recomendaciones e Investigaciones Futuras

### 9.1. Conclusiones

#### 9.1.1. De la teoría

- Este trabajo ha pretendido realizar una pequeña introducción a algunas características de las Redes Neuronales. De hecho, aún los estudios más avanzados que existen hoy en día sobre el tema están muy alejados de entender el funcionamiento del cerebro, que fue su motivación inicial. El tema en realidad es muy amplio. Sin embargo, pese a que hemos visto una parte pequeña del total, hemos podido apreciar algunas cualidades de este mecanismo de procesamiento de información. Debemos destacar que es posible modelar el funcionamiento de una neurona en forma extremadamente simple, y sin embargo, poseer una gran capacidad, mostrando la sencillez y la complejidad unidas de un modo maravilloso.
- La teoría de Redes Neuronales encontrada en la mayoría de las referencias indica que existen dos subconjuntos (entrenamiento y validación) para la Red Neuronal, mientras que MATLAB posee tres subconjuntos (entrenamiento, validación y prueba).

- Hoy en día las redes neuronales son entrenadas para resolver problemas que son difíciles para las computadoras convencionales o los seres humanos.
- Los sistemas de medición de la precipitación se encuentran en una evolución continua, logrando obtener resultados cada vez más precisos.
- La teledetección se está convirtiendo en una herramienta básica en el seguimiento de la evolución de los recursos hídricos.
- En el mundo entero existe una importante comunidad científica y universitaria que está trabajando actualmente en el desarrollo de nuevas aplicaciones relacionadas con el agua basadas en técnicas de teledetección. Países desarrollados están apostando fuertemente para que las técnicas de teledetección sean parte del soporte del seguimiento de los recursos hídricos.
- Los modelos que se elaboran para interpretar los datos de Teledetección, deberán tener como objetivo eliminar los efectos ocasionados por la variabilidad en las condiciones de captación, la distorsión provocada por la atmósfera, y la influencia de parámetros tales como la posición del Sol, pendiente, exposición, y altitud.

### **9.1.2. De la metodología**

- Se encuentra que la zona de estudio se enmarca dentro de las coordenadas geográficas correspondientes a las cartas nacionales que corresponden a las hojas 26-O, 26-Ñ, 27-O y 27-Ñ.
- Se logra adquirir datos de precipitaciones mensuales del algoritmo 3B43 V7 del TRMM para las estaciones involucradas en este estudio, los cuales sirvieron como datos de ingreso de la Red Neuronal.
- Se logra adquirir datos de precipitaciones mensuales (acumulaciones diarias) del SENAMHI para las estaciones involucradas en este estudio, los cuales sirvieron como objetivos de la Red Neuronal.

- Se logró establecer un modelo metaheurístico cuyo resultado son las precipitaciones mensuales in situ (aproximadas); el modelo se utiliza para extender las precipitaciones in situ a otros puntos en el área de interés.

### 9.1.3. Del modelo de Red Neuronal utilizado


- El hecho de que los modelos de redes neuronales artificiales exhiban un desarrollo comparable e incluso mejor que los modelos estocásticos sugiere que esta investigación puede proveer una herramienta útil en la solución de tipos similares de problemas en la gestión y estudio de los recursos hídricos.
- El modelo de Red Neuronal establecido en este estudio (ver figura 9.1) es ampliamente utilizado y recomendado en lo referente a Series Temporales (Referencia [13]).
- La gran cantidad de neuronas en la capa oculta (120) obedece a que la Red Neuronal tuvo que realizar el entrenamiento (establecimiento de parámetros de la Red) para tres tipos de ingresos que representaban el mes, el año y el valor de la precipitación.
- Los parámetros de la Red Neuronal<sup>1</sup> (pesos y umbrales<sup>2</sup>) establecidos en el presente estudio se muestran en el cuadro 9.1 y sirven para el uso posterior de la Red Neuronal a otras ubicaciones sobre la Cuenca del Río Cachi.
- La salida consta de una neurona debido a que sólo se obtiene el valor de la precipitación mensual in situ aproximada.

---

<sup>1</sup>En el capítulo 7 de este estudio se muestra la matriz de ingreso y la matriz objetivo establecidas para La Red Neuronal.

<sup>2</sup>En el cuadro 9.1 se debe notar que los pesos de la capa de entrada se denotan por IW (Input Weight) y representan a una matriz de orden 120 x 3; los pesos de la capa oculta se denotan por LW (Layer Weight) y representan a una matriz de orden 1 x 120; los umbrales de la capa oculta se denotan por b1 y representan a una matriz de orden 120 x 1; los umbrales de la capa de salida se denotan por b2 y representan una matriz de orden 1 x 1.

**Figura 9.1:** Red Neuronal establecida en el presente estudio con 120 neuronas en la Capa Oculta y 1 en la capa de Salida.



**Fuente:** Elaboración Propia.

**Cuadro 9.1:** Pesos y Umbrales de la Red Neuronal.

IW			LW	b1	b2
-3.7605	5.3574	-2.0391	6.8574	0.0368	0.1736
-3.4051	-2.3968	-5.2663	6.9942	0.3471	
4.9191	0.3274	-4.8661	-6.8614	-1.1924	
6.4221	1.5959	1.9868	-6.5596	-1.0983	
-4.8149	-2.0711	-3.4608	7.3165	1.4247	
-3.2998	3.6738	4.6954	6.2612	0.8237	
4.4279	-5.8194	1.5385	-5.6281	-1.2093	
0.6639	-5.0719	4.9741	-5.8143	-0.9653	
3.7465	4.0037	-4.2682	-6.2066	-1.1893	
-6.2584	3.8940	1.3557	5.2721	0.7468	
7.2451	2.1992	-1.2437	-4.9764	1.1879	
5.4473	3.9128	1.7847	-5.5600	1.0357	
1.1166	4.0851	-6.5230	-5.1075	-2.2853	
-4.5786	4.2941	-3.8440	4.9092	-0.6084	
-2.8028	6.1446	1.9439	4.9457	-1.2277	
-3.7310	-3.5534	4.6657	5.0559	0.6549	
-2.9174	-5.5671	1.6008	5.5193	-1.2422	
-1.4811	-4.0228	-4.2628	6.1254	0.4175	
-4.9688	-1.1834	-5.1938	4.7307	0.9880	
-3.8981	-2.5258	5.1642	4.8985	-0.7664	
1.0156	-2.6194	7.5300	-5.8464	2.8812	
-4.2705	-3.5326	4.5113	3.9249	-0.3668	
-6.1485	-2.4152	-0.8741	5.1538	-0.6360	
2.8251	0.8914	7.2776	-2.8379	-0.5589	
6.4170	2.5484	1.8267	-3.5737	-0.8639	
2.8375	6.3390	-0.1239	-3.6137	-0.0790	
-5.0792	-4.8695	0.0600	3.8473	0.5042	
6.4423	-2.9449	-0.7301	-3.4449	0.3402	
-4.6535	4.3465	-1.9830	3.9521	-0.2967	
-4.2408	-4.2121	-3.4514	3.4844	0.0101	
1.7830	-5.4920	3.4802	-4.3686	1.3877	
1.2011	-6.7803	0.0783	-3.4450	0.5362	

Continúa en la siguiente página

**Cuadro 9.1 – Continúa de la página anterior**

IW			LW	b1	b2
-5.2966	2.5361	3.7163	2.6056	-0.4177	
1.7512	-5.3253	2.2561	-4.5395	-0.5314	
4.4464	-1.3712	4.3616	-4.7880	1.8240	
1.4245	-2.5371	-6.9235	-2.7270	1.2016	
-1.8171	-5.5565	3.8906	3.1301	-0.8934	
0.6437	-4.3917	5.6899	-2.5124	-1.1292	
-0.2480	5.8206	-5.1386	-2.6719	1.5879	
5.0772	2.3155	-4.0644	-2.4218	-0.4150	
6.8198	0.2397	-2.1853	-1.6745	0.4523	
3.1883	-5.9688	1.8001	-2.4831	1.0217	
-6.3850	-1.3029	2.0257	2.3518	-0.5573	
-2.2967	4.1560	4.5874	2.4284	-0.0740	
-5.0181	-4.8495	-0.4603	1.8040	-1.2100	
-5.6655	1.5737	-3.0586	2.9037	-0.1476	
-1.2189	-5.3034	5.1564	-0.0173	-0.5254	
0.2681	-2.2863	7.3872	2.1682	1.6064	
-0.5536	-6.0668	-3.2897	1.5702	0.6823	
1.4662	4.8759	-5.3035	-0.9334	-1.2896	
4.3248	5.2226	1.0799	-1.6111	-0.0033	
5.9681	-1.6454	3.1041	-1.6926	0.6759	
-2.6474	-4.9610	-4.6214	0.0408	-0.9380	
5.8959	2.5909	2.5585	-0.7464	-0.2109	
4.2844	-1.9446	5.1801	-0.3643	-1.3386	
3.9933	-4.8752	2.6552	-1.0239	-0.6252	
-1.2017	4.9665	-4.1981	0.0844	0.9694	
6.7388	-1.3969	1.9390	-0.6486	-0.2543	
1.5182	-0.5933	-7.2061	-0.7153	-1.4908	
2.4732	5.2828	4.4153	-0.2910	1.4318	
0.6564	-5.1585	-5.2074	0.9437	-0.2950	
0.1801	5.6828	4.4244	-0.7649	-1.3364	
-3.8866	-5.6845	0.3670	-0.3868	0.0180	
-3.1764	-4.4129	3.6890	-1.4882	0.3819	
-3.6486	4.4275	-4.9640	-0.6563	-1.2162	
Continúa en la siguiente página					

**Cuadro 9.1 – Continúa de la página anterior**

IW			LW	b1	b2
3.5209	-2.6491	5.6681	2.1838	1.1439	
-5.0732	4.5509	-2.3749	-0.9304	2.1180	
-5.2528	1.5052	4.3235	-1.0354	0.1689	
4.2391	-3.8482	4.2514	0.6244	-1.7269	
5.6689	0.7553	-3.9410	1.0235	1.0299	
4.1387	-3.8615	-3.8278	0.8989	-1.3981	
0.8218	4.3757	-5.4686	0.4885	1.9246	
2.5828	4.3442	4.9449	1.8315	-1.5099	
4.4441	-4.1622	3.8127	2.4204	1.8384	
0.9274	6.7656	-0.3426	1.9104	-0.3096	
6.8405	1.5508	-0.1879	0.9003	0.0334	
5.4607	-4.0882	-1.6872	1.2369	-1.1951	
5.4071	-3.1166	2.5627	2.3036	0.3314	
6.2422	-0.3285	3.0570	1.9662	-0.1809	
3.2698	4.5660	4.3661	2.8501	1.0678	
-5.1552	-2.5216	-3.9882	-2.9082	0.4100	
4.2510	-4.3476	4.3273	1.2404	0.2402	
4.3351	-3.8583	-3.7039	2.6025	0.6767	
4.8210	-3.8205	-2.9569	2.9457	0.4060	
5.8061	-1.7642	-3.6389	3.4138	1.7895	
-3.8784	5.3233	-2.1645	-2.9167	-0.1098	
4.3509	5.6248	-1.8382	2.6242	0.6861	
-5.5357	3.0977	2.8498	-3.1143	-0.2566	
3.0583	-1.7606	-5.7736	3.3900	0.3450	
2.8106	-2.1814	-6.0421	3.5538	0.7096	
-7.3612	0.2396	0.1745	-2.5625	0.5782	
-3.8299	-4.1505	3.4447	-4.1539	0.6059	
5.1468	3.0001	3.9678	3.7166	0.4445	
-4.2767	-3.2810	5.2092	-3.8922	1.7390	
4.3372	-0.9623	-5.1702	4.3119	-0.9566	
3.4485	-3.1153	-5.0253	4.2166	-0.2038	
3.1594	5.7196	4.4295	2.0865	-0.8160	
-4.2343	4.8571	2.9795	-4.7293	1.6106	
Continúa en la siguiente página					

**Cuadro 9.1 – Continúa de la página anterior**

IW			LW	b1	b2
-4.7895	-4.4371	-2.4415	-4.3943	0.4976	
0.1022	-4.7734	6.2341	-5.0885	2.9742	
-6.0753	4.3780	-1.6494	-3.3675	1.1169	
1.6877	-4.5389	-5.7363	4.8956	1.6670	
-4.4612	4.0889	-4.4523	-4.1744	0.1172	
-2.1847	-3.7605	6.0065	-4.4914	-0.4933	
1.8755	5.2242	4.9743	5.7523	-1.5159	
-2.0291	-6.0289	3.6613	-5.1967	-1.8099	
4.0319	-4.1873	4.2750	5.1464	0.9994	
-3.1099	4.0111	-6.3743	-5.1364	1.9087	
2.4992	6.2017	0.5515	5.8036	-0.4207	
-3.8493	4.1100	4.2978	-5.5126	0.6361	
2.5490	-6.3872	-0.7142	5.8518	-0.0308	
-4.6666	4.5876	-3.0374	-5.7053	-1.2380	
-2.8053	-3.0231	-5.0466	-6.5006	-0.9030	
-4.2132	-4.4814	2.7996	-6.3746	-0.4600	
3.8208	-4.3418	2.8068	6.8459	0.2846	
5.9955	0.4913	-2.1093	6.9282	-0.6335	
4.6043	-1.7676	4.5359	6.7531	-0.8590	
-4.7982	3.3966	1.9907	-7.5285	0.3057	
-4.9599	-1.8753	-4.0416	-7.0679	-0.2843	
1.9614	6.3873	0.0826	7.1241	0.2538	

**Fuente:** Elaboración Propia.

#### 9.1.4. De los resultados

- La caracterización de la precipitación ha permitido cambiar nuestra perspectiva en cuanto a algunas suposiciones que se creían ciertas pero no lo son del todo, y revela que la precipitación es algo realmente muy complejo.
- Alta incertidumbre de detección de lluvia ligera, todavía existe en la precipitación diaria del TRMM, que conduce a diferentes errores: sobreestimaciones, falsas alarmas y omisiones en la detección.

- La precipitación diaria del TRMM y la precipitación diaria in situ (pluviómetro) no tienen una tendencia similar sobre la Cuenca del Río Cachi debido a que la Misión de Medición de LLuvias Tropicales posee instrumentos de medición de precipitación muy avanzados (radares) sobre la superficie de la Tierra que se mueven en territorios como Estados Unidos.
- Se tiene ligeramente mejor desempeño en la versión 3B43 V7 sobre la versión 3B43 V6 en aspectos de detectabilidad y precisión cuantitativa.
- Debido a las gráficas comparativas antes de diseñar la Red Neuronal de este estudio, se concluye que la salida de la Red Neuronal debe tener una tendencia ligeramente similar a la obtenida directamente del algoritmo 3B43 V7 del TRMM.
- Las limitaciones en cuanto al número y disposición de estaciones pluviométricas por parte del SENAMHI sobre la Cuenca del Río Cachi originan que en este estudio se obtengan resultados aceptables sólo en una porción de la superficie de la Cuenca del Río Cachi.
- En ubicaciones sobre la Cuenca del Río Cachi donde la salida de la red no sea aceptable se puede usar directamente los valores derivados del algoritmo 3B43 V7 del TRMM.

#### 9.1.5. De la tesis

- La presente tesis cumpliendo con los objetivos trazados en su planteamiento tiene un carácter científico y aplicativo en el campo de la ingeniería civil; lo primero por el desarrollo con una técnica avanzada y actual, lo segundo por la aplicación a un caso real como es la Cuenca del Río Cachi como un elemento de validación del modelo propuesto.
- El estudio de modelos matemáticos de simulación hidrológica e hidráulica, se ha desarrollado en forma acelerada en los últimos tiempos, debido al desarrollo de software en la ingeniería. Una de las utilidades de estos modelos es la

determinación de los caudales medios (Aportaciones mensuales), en una cuenca determinada, para su aprovechamiento hídrico. La presente investigación proporciona precipitaciones mensuales in situ (aproximadas) que sirven para implementar los métodos de Témez y Lutz Scholz (Referencia [9]) por ejemplo.

## 9.2. Recomendaciones

- El SENAMHI como institución encargada a nivel nacional debiera establecer un proyecto de medición de precipitación en todo el territorio peruano de al menos 15 años (continuos y completos) para el desarrollo de investigaciones con resultados eficientes. Investigaciones revisadas para este estudio poseen datos de precipitación de alrededor de 15 años.
- Difundir la aplicación de las Redes Neuronales a múltiples campos de la ingeniería civil, para la realización de estudios a nivel regional y/o nacional.

## 9.3. Investigaciones futuras

- Introducción de nuevos algoritmos de entrenamiento, así como aumentar la flexibilidad de los ya existentes, es decir, que el investigador sea capaz de elegir mayor número de parámetros.
- Introducción de nuevos tipos de redes, pues si bien es verdad que las más utilizadas son las redes de retro-propagación y de base radial, en algunos tipos de problemas o aplicaciones podría ser más óptimo la utilización de otro tipo de red.
- La extensión de las Series Temporales es posible utilizando Redes Neuronales (Redes Dinámicas) (Referencia [13]). Se debe tener en cuenta que de acuerdo a las investigaciones es recomendable extender la Serie Temporal a partir de una Salida de Red Neuronal (Referencia [3]).

- Los Modelos Hidrológicos planteados en investigaciones avanzadas de hidrología utilizan ampliamente valores de precipitación mensuales. Pudiéndose establecer un modelo en alguna parte sobre la Cuenca del Río cachi.
- A medida que el SENAMHI vaya recolectando valores de precipitación es posible extender el tiempo de validación de este estudio, siguiendo el mismo procedimiento planteado.
- Finalmente, la NASA y la JAXA han programado poner en orbita para el 2014 dos radares de precipitación en un mismo satélite, como parte del proyecto GPM, uno de ellos es un radar muy similar al radar de precipitación a bordo del TRMM así que el uso y manejo de los datos del TRMM nos prepara para los nuevos datos que se tendrán en un futuro.

# Referencias

- [1] Shefali Aggarwa. *PRINCIPLES OF REMOTE SENSING*. Photogrammetry and Remote Sensing Division Indian Institute of Remote Sensing, Dehra Dun, 2010.
- [2] Allen Bateman. *HIDROLOGÍA BÁSICA Y APLICADA*. Grupo de Investigación en Transporte de Sedimentos, 2007.
- [3] Rosmina Bustami, Nabil Bessaih, Charles Bong, and Suhaila Suhaili. *Artificial Neural Network for Precipitation and Water Level Predictions of Bedup River*. IAENG International Journal of Computer Science, 2000.
- [4] Wendor Chereque. *HIDROLOGÍA para estudiantes de ingeniería civil*. Pontificia Universidad Católica del Perú, 1990.
- [5] VEN TE CHOW, DAVID MAIDMENT, and LARRY MAYS. *HIDROLOGÍA APLICADA*. McGRAW-HILL, 1994.
- [6] Steven Chávez. *Caracterización de Tormentas en el Valle del Mantaro mediante Sensoramiento Remoto*. Pontificia Universidad Católica del Perú, 2013.
- [7] Thomas Condom, Pedro Rau, and Jhan Espinoza. *Correction of TRMM 3B43 monthly precipitation data over the mountainous areas of Peru during the period 1998-2007*. John Wiley and Sons, 2010.
- [8] Pedro Isasi e Inés Galván. *REDES DE NEURONAS ARTIFICIALES Un enfoque práctico*. PEARSON Prentice Hall, 2004.

- [9] Raúl Evanan. *COMPARACIÓN DE MODELOS HIDROLÓGICOS PRECIPITACIÓN-ESCORRENTÍA EN EL CÁLCULO DE APORTACIONES MENSUALES, APLICADOS A LA CUENCA DEL RÍO CACHI*. UNSCH, 2007.
- [10] Bernardo Fontal, Trino Suárez, Marisela Reyes, Fernando Bellandi, Ricardo Contreras, and Isolda Romero. *El Espectro Electromagnético y sus Aplicaciones*. Escuela Venezolana para la Enseñanza de la Química, 2005.
- [11] Amos Gilat. *Matlab Una introducción con ejemplos prácticos*. EDITORIAL REVERTÉ, 2005.
- [12] Simon Haykin. *NEURAL NETWORKS A Comprehensive Foundation*. PEARSON Prentice Hall, 1999.
- [13] Mark Hudson, Martin Hagan, and Howard Demuth. *Neural network Toolbox User's Guide R2014a*. The MathWorks, Inc, 2014.
- [14] Nazrul Islam, Someshwar Das, and Hiroshi Uyeda. *Calibration of TRMM Derived Rainfall Over Nepal During 1998-2007*. The Open Atmospheric Science Journal, 2010.
- [15] Luis Joyanes. *FUNDAMENTOS DE PROGRAMACIÓN ALGORITMOS Y ESTRUCTURA DE DATOS*. Mc Graw Hill, 1999.
- [16] Mauricio Labrador, Juan Évora, and Manuel Arbelo. *Satélites de Teledetección para la Gestión del Territorio*. Consejería de Agricultura, Ganadería, Pesca y Aguas del Gobierno de Canarias, 2010.
- [17] Sergio Ledesma. *Las Redes Neuronales implementación y consideraciones prácticas*. Fifth Mexican International Conference on Artificial Intelligence, 2010.
- [18] Holly Moore. *MATLAB para ingenieros*. PEARSON Prentice Hall, 2007.

- [19] César Pérez. *MATLAB y sus Aplicaciones en las Ciencias y la Ingeniería*. PEARSON Prentice Hall, 2002.
- [20] Fernando Izaurieta y Carlos Saavedra. *Redes Neuronales Artificiales*. Departamento de Física, Universidad de Concepción, Concepción, Chile, 2008.
- [21] Samuel Nelson y Frederick Merrit. *MANUAL DEL INGENIERO CIVIL - INGENIERÍA HIDRÁULICA*. McGraw-Hill, 1984.
- [22] Oscar Rodriguez y Harold Arredondo. *MANUAL PARA EL MANEJO Y PROCESAMIENTO DE IMÁGENES SATELITALES OBTENIDAS DEL SENSOR REMOTO MODIS DE LA NASA, APLICADO EN ESTUDIOS DE INGENIERÍA CIVIL*. Pontificia Universidad Javeriana, Colombia, 2005.

# Parte VI

## Anexos

# Apéndice A

## Análisis de Registros Anuales

### A.1. Análisis de Homogeneidad o Consistencia

#### A.1.1. Concepto de homogeneidad de la serie

Una serie de datos es llamada homogénea si es una muestra única de una población. Si la serie es inhomogénea, se le debe hacer ajustes o correcciones para hacerla homogénea, de manera que las estimaciones estadísticas muestrales sean válidas estimaciones de los parámetros poblacionales.

La homogeneidad de una serie se puede perder por un sin número de causas, las cuales pueden ser diferenciadas en dos grupos; primero, las debidas a cambios físicos en la propia estación pluviométrica y segundo, las originadas por las modificaciones o cambios en el medio ambiente.

#### A.1.2. Tipos de Pruebas Estadísticas de Homogeneidad

El test o prueba estadística de homogeneidad, presenta una hipótesis nula y una regla para aceptarla o rechazarla en base a su probabilidad de ocurrencia. Si dicha probabilidad es pequeña, será concluido que la serie es inhomogénea; si es grande, la decisión es que es homogénea.

### A.1.3. Prueba Estadística de la t de Student

Cuando la causa de la pérdida de homogeneidad de la serie es probable que sea un abrupto cambio en la media, la prueba paramétrica de la t de Student es especialmente útil. La prueba es poderosa para detectar la inconsistencia en la media, además de ser un test robusto, excepto cuando la longitud de los dos períodos seleccionados para comparación de sus medias son desiguales, pues entonces la distribución de los datos puede no ser sesgada. Se entiende que un test es robusto cuando es insensible a la forma de distribución de probabilidades de la serie.

**Cuadro A.1:** Prueba Estadística de la t de Student (Estación Huanta - SENAMHI).

Prueba t para dos muestras suponiendo varianzas iguales		
	Variable 1	Variable 2
Media	556.533333333333	547.93
Varianza	4008.50333333334	133.497800000001
Observaciones	3	2
Varianza Agrupada	2716.83482222223	
Diferencia hipotética de las medias	0	
Grados de Libertad	3	
Estadístico t	0.180811377701073	
P (T<=t) una cola	0.434020440680359	
Valor crítico de t (una cola)	2.35336343480182	
P (T<=t) dos colas	0.868040881360719	
Valor crítico de t (dos cola)	3.18244630528371	

**Fuente:** Elaboración Propia.

Los resultados muestran que la serie correspondiente a la Estación Huanta (SE-NAMHI) es homogénea.

**Cuadro A.2:** Prueba Estadística de la t de Student (Estación Huanta - Salida de la Red Neuronal).

Prueba t para dos muestras suponiendo varianzas iguales		
	Variable 1	Variable 2
Media	582.177833333333	622.6381
Varianza	4230.01205908332	429.17468288
Observaciones	3	2
Varianza Agrupada	2963.06626701555	
Diferencia hipotética de las medias	0	
Grados de Libertad	3	
Estadístico t	-0.814232965849527	
P (T<=t) una cola	0.2375682128493	
Valor crítico de t (una cola)	2.35336343480182	
P (T<=t) dos colas	0.475136425698601	
Valor crítico de t (dos cola)	3.18244630528371	

**Fuente:** Elaboración Propia.

Los resultados muestran que la serie correspondiente a la Estación Huanta (Salida de la Red Neuronal) es homogénea.

**Cuadro A.3:** Prueba Estadística de la t de Student (Estación La Quinua - SENAMHI).

Prueba t para dos muestras suponiendo varianzas iguales		
	Variable 1	Variable 2
Media	840.666666666667	834.4
Varianza	25034.0133333334	9521.99999999999
Observaciones	3	2
Varianza Agrupada	19863.3422222223	
Diferencia hipotética de las medias	0	
Grados de Libertad	3	
Estadístico t	0.0487080849767586	
P (T<=t) una cola	0.482106648817348	
Valor crítico de t (una cola)	2.35336343480182	
P (T<=t) dos colas	0.964213297634697	
Valor crítico de t (dos cola)	3.18244630528371	

**Fuente:** Elaboración Propia.

Los resultados muestran que la serie correspondiente a la Estación La Quinua (SE-NAMHI) es homogénea.

**Cuadro A.4:** Prueba Estadística de la t de Student (Estación La Quinua - Salida de la Red Neuronal).

Prueba t para dos muestras suponiendo varianzas iguales		
	Variable 1	Variable 2
Media	828.684033333333	786.02195
Varianza	14726.6966637035	2122.09837812499
Observaciones	3	2
Varianza Agrupada	10525.163901844	
Diferencia hipotética de las medias	0	
Grados de Libertad	3	
Estadístico t	0.455531327069356	
P (T<=t) una cola	0.339838096645408	
Valor crítico de t (una cola)	2.35336343480182	
P (T<=t) dos colas	0.679676193290817	
Valor crítico de t (dos cola)	3.18244630528371	

**Fuente:** Elaboración Propia.

Los resultados muestran que la serie correspondiente a la Estación La Quinua (Salida de la Red Neuronal) es homogénea.

**Cuadro A.5:** Prueba Estadística de la t de Student (Estación San Pedro de Cachi - SENAMHI).

Prueba t para dos muestras suponiendo varianzas iguales		
	Variable 1	Variable 2
Media	814.633333333333	662.14
Varianza	14074.1033333334	10910.5992
Observaciones	3	2
Varianza Agrupada	13019.6019555556	
Diferencia hipotética de las medias	0	
Grados de Libertad	3	
Estadístico t	1.46400522698725	
P (T<=t) una cola	0.119701900480244	
Valor crítico de t (una cola)	2.35336343480182	
P (T<=t) dos colas	0.239403800960488	
Valor crítico de t (dos cola)	3.18244630528371	

**Fuente:** Elaboración Propia.

Los resultados muestran que la serie correspondiente a la Estación San Pedro de Cachi (SENAMHI) es homogénea.

**Cuadro A.6:** Prueba Estadística de la t de Student (Estación San Pedro de Cachi - Salida de la Red Neuronal).

Prueba t para dos muestras suponiendo varianzas iguales		
	Variable 1	Variable 2
Media	841.4376	661.25665
Varianza	15955.8949209898	9206.28155520488
Observaciones	3	2
Varianza Agrupada	13706.0237990615	
Diferencia hipotética de las medias	0	
Grados de Libertad	3	
Estadístico t	1.68594636626147	
P (T<=t) una cola	0.0951962972977324	
Valor crítico de t (una cola)	2.35336343480182	
P (T<=t) dos colas	0.190392594595465	
Valor crítico de t (dos cola)	3.18244630528371	

**Fuente:** Elaboración Propia.

Los resultados muestran que la serie correspondiente a la Estación San Pedro de Cachi (Salida de la Red Neuronal) es homogénea.

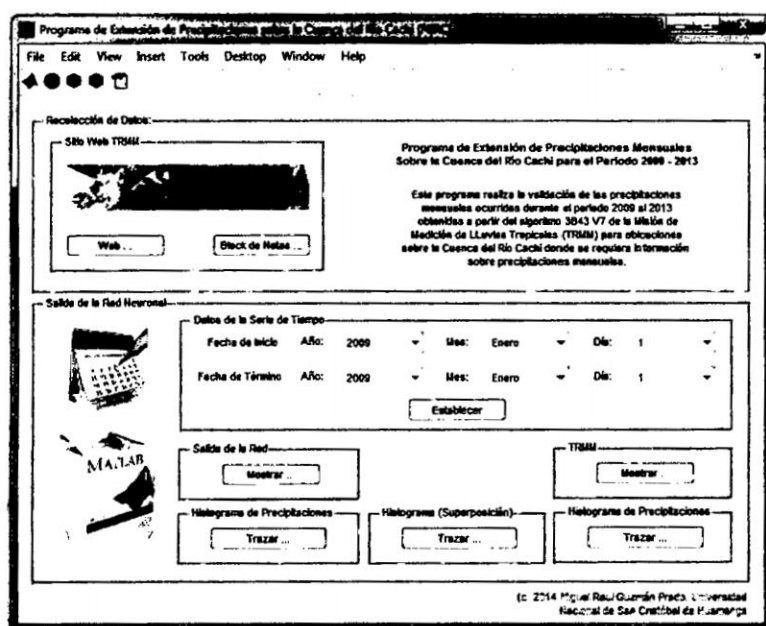
# Apéndice B

## Guía de Usuario del Programa PERC

### B.1. Ventana Principal

El programa PERC (Programa de extensión de precipitaciones mensuales sobre la Cuenca del Río Cachi) consta en principio de una ventana principal, tal como se muestra en la figura B.1; esta ventana contiene barras de menús, barras de herramientas, listas desplegables y botones para el establecimiento de datos y resultados.


Figura B.1: Ventana principal del programa PERC.



Fuente: Elaboración propia.

La figura B.2 muestra una breve explicación de cada componente de este ventana principal del programa PERC.

Figura B.2: Descripción de las componentes del programa PERC.

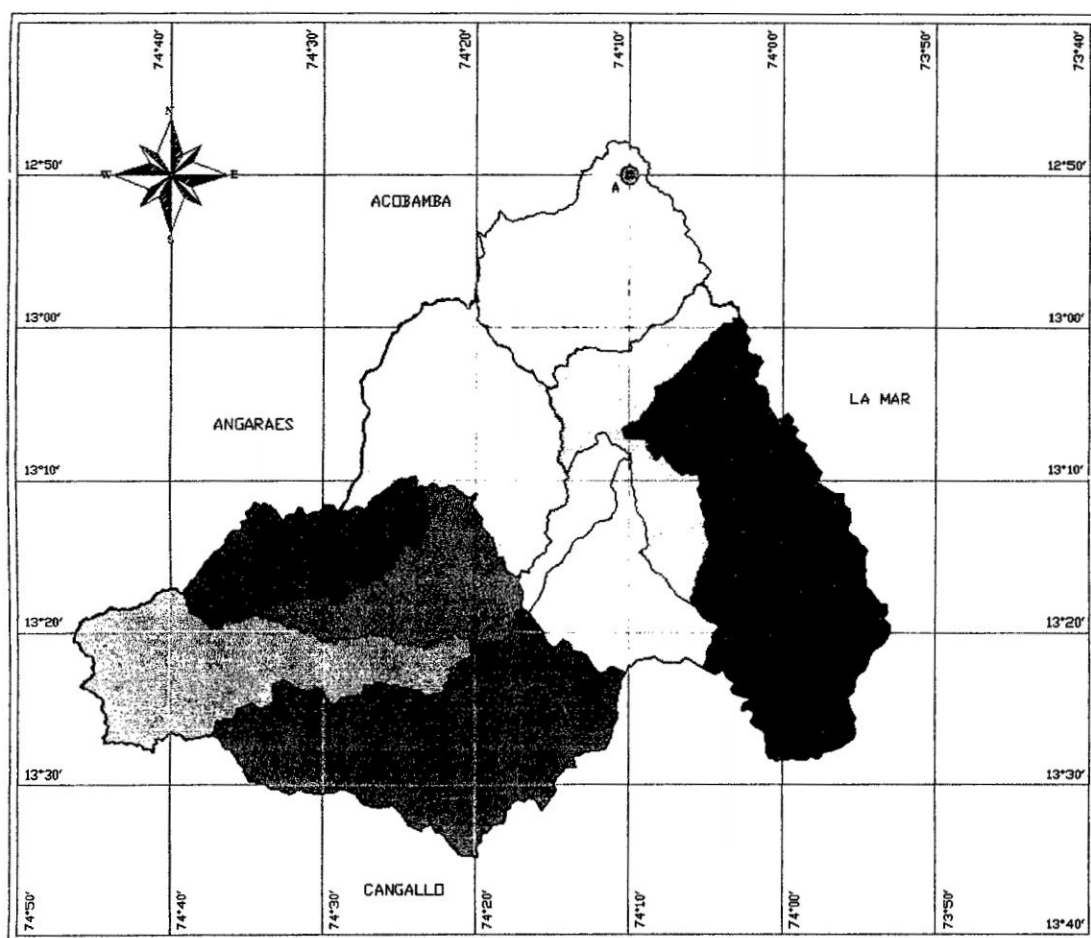


Fuente: Elaboración propia.

## B.2. Adquisición de datos del TRMM

Aquí se muestra como un ejemplo la adquisición de datos de un punto denominado A que se encuentra ubicado sobre una subcuenca de la Cuenca del Río Cachi (Ver figura B.3).

**Figura B.3:** Punto A sobre la Cuenca del Río Cachi.



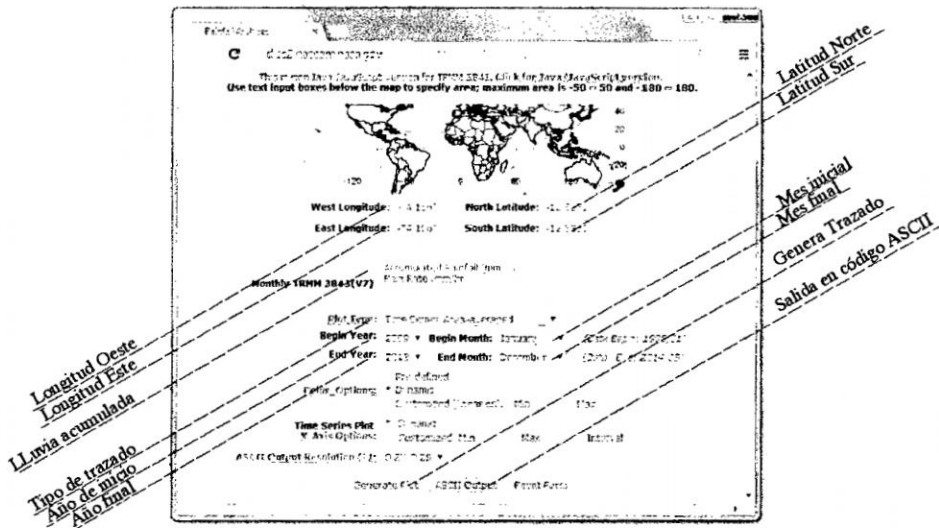
**Fuente:** Elaboración propia.

En la ventana principal del programa PERC haciendo click en el botón Web se ingresa al sitio Web del Algoritmo 3B43 del TRMM, luego se procede a ingresar datos relacionados a las coordenadas geográficas (latitudes y longitudes), tipo de trazado para la serie temporal y periodo de duración de la serie temporal; de acuerdo a las descripciones mostradas en la figura B.4.

El sitio Web del algoritmo 3B43 V7 del TRMM después de ingresar los datos nos


muestra haciendo click en el botón Generate Plot una gráfica de la serie de tiempo relacionada a las precipitaciones mensuales de la coordenada geográfica establecida tal como se muestra en la figura B.5; de la misma manera al hacer click en el botón ASCII Output nos muestra las precipitaciones mensuales en código ASCII como se puede observar en la figura B.6.

**Figura B.4:** Archivo de precipitaciones del Algoritmo 3B43 del TRMM.



**Fuente:** Tropical Rainfall Measuring Mission (TRMM)-NASA.

**Figura B.5:** Gráfico de precipitaciones del Algoritmo 3B43 del TRMM.



**Fuente:** Tropical Rainfall Measuring Mission (TRMM)-NASA.

**Figura B.6:** Valores de precipitaciones del Algoritmo 3B43 del TRMM.

```

Selected parameters: Monthly TRMM 3B43(V7) Accumulated Rainfall
Selected points: lat=(12.5535), lon=(74.1678)
Undefined/Missing Value: -9999.9
Units: mm
Time (year:month)  AccRain
2009:01            115.8520
2009:02            172.5130
2009:03            116.4570
2009:04            104.0990
2009:05            37.6143
2009:06            20.1245
2009:07            16.6350
2009:08            82.2579
2009:09            40.6325
2009:10            65.9063
2009:11            40.9438
2009:12            92.7523
2010:01            155.5940
2010:02            78.8960
2010:03            140.8550
2010:04            94.1630
2010:05            44.8227
2010:06            6.6093
2010:07            21.1816
2010:08            38.9321
2010:09            34.4467
2010:10            86.8045
2010:11            44.8477
2010:12            103.7950
2011:01            141.3240
2011:02            160.4510
2011:03            234.4450
2011:04            94.8714
2011:05            35.7978
2011:06            1.6459
2011:07            91.1045
2011:08            16.0016
    
```

**Fuente:** Tropical Rainfall Measuring Mission (TRMM)-NASA.

### B.3. Establecimiento de datos para presentación de Series Temporales

El paso del establecimiento de datos se realiza debido a las capacidades potenciales que posee MATLAB para relizar gráficos bidimensionales y muestra de matrices en forma tabular. Para ello en primer lugar se copia la salida de datos en código ASCII del algoritmo 3B43 V7 del TRMM a partir del primer mes de la serie temporal (es decir, sin los títulos e indicaciones) y se pega en el archivo del block de notas que se abre al hacer click en el botón Block de Notas de la ventana principal del programa PERC, tal como se muestra en la figura B.7. Finalmente se realiza el procedimiento de guardar y cerrar. En segundo lugar se establece en la ventana principal del programa PERC en la parte de Datos de la Serie de Tiempo las fechas de inicio y término (Ver figura B.8) para que MATLAB mediante la aplicación de algunos comandos trabaje con las cadenas de caracteres relacionadas y establezca salidas que serán mostradas en la parte de resultados.

Figura B.7: Valores de precipitaciones del TRMM copiados en un bloc de notas.

Año	Mes	Valor
2009	01	113.9830
2009	02	172.3130
2009	03	114.4070
2009	04	104.0990
2009	05	37.6143
2009	06	10.1245
2009	07	16.6390
2009	08	52.3879
2009	09	40.6523
2009	10	63.9543
2009	11	60.9438
2009	12	92.2513
2010	01	155.5940
2010	02	75.8840
2010	03	140.8390
2010	04	54.1633
2010	05	44.3207
2010	06	8.0093
2010	07	21.1814
2010	08	38.9831
2010	09	34.8467
2010	10	86.5043
2010	11	44.9477
2010	12	103.7980
2011	01	131.3240
2011	02	160.4510
2011	03	234.4430
2011	04	84.5714
2011	05	38.7978
2011	06	1.6459
2011	07	31.1045
2011	08	16.0016

Fuente: Elaboración Propia.

Figura B.8: Establecimiento de datos temporales en el programa PERC.

Programa de Extensión de Precipitaciones sobre la Cuenca del Río Cachi (PERC)

Recolección de Datos:

Sitio Web TRMM:  Web

Programa de Extensión de Precipitaciones Mensuales Sobre la Cuenca del Río Cachi para el Período 2009 - 2013

Este programa realiza la validación de las precipitaciones mensuales ocurridas durante el período 2009 al 2013 obtenidas a partir del algoritmo 3B43 V7 de la Misión de Medición de Lluvias Tropicales (TRMM) para ubicaciones sobre la Cuenca del Río Cachi donde se requiera información sobre precipitaciones mensuales.

Salida de la Red Neuronal:

Fecha de Inicio: Año: 2009 Mes: Enero Día: 1

Fecha de Término: Año: 2013 Mes: Diciembre Día: 31

Salida de la Red:

Histograma de Precipitaciones:  Histograma (Superposición):  Histograma de Precipitaciones:

(c) 2014 (Figueroa) Guzmán Prado, Universidad Nacional de San Cristóbal de Huamanga

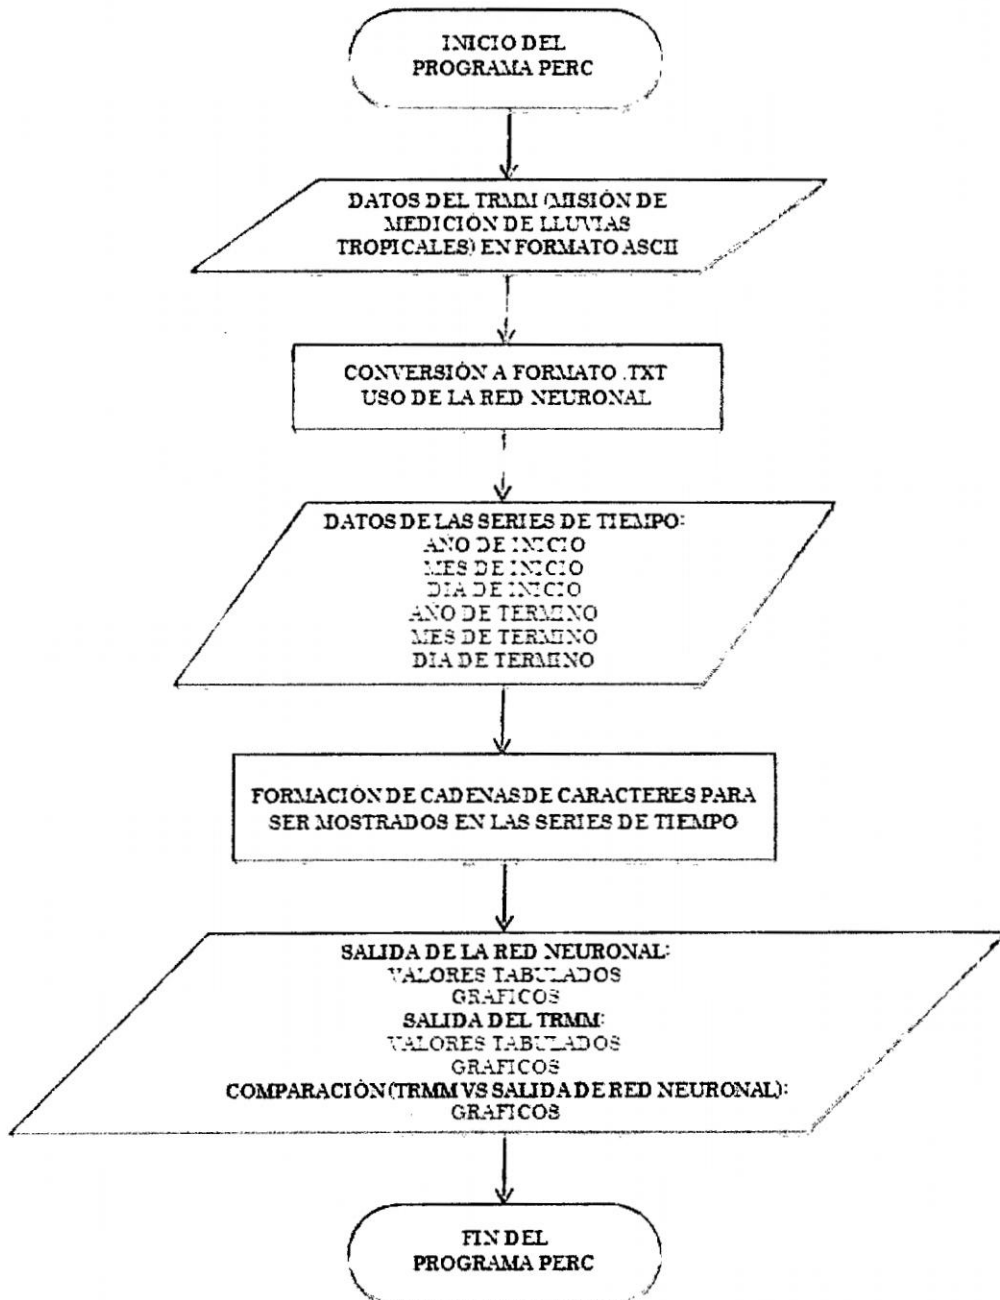
Fuente: Elaboración Propia.

## B.4. Diagrama de flujo del programa PERC

El programa PERC (Programa de extensión de precipitaciones mensuales sobre la Cuenca del Río Cachi) realiza en primer lugar la adquisición de datos del TRMM en formato ASCII para luego procesarlos y pasarlos a un archivo del block de notas.

Luego realiza el ingreso de datos a la Red Neuronal para obtener la Salida de la Red Neuronal. Seguidamente se ingresa valores temporales de inicio y término del periodo de validación para ser procesados. Por último se muestra valores tabulares y gráficos de las series temporales establecidas en el presente estudio. La figura B.9 muestra el Diagrama de flujo (Referencia [15]) correspondiente al Programa PERC.

**Figura B.9:** Diagrama de flujo del programa PERC.

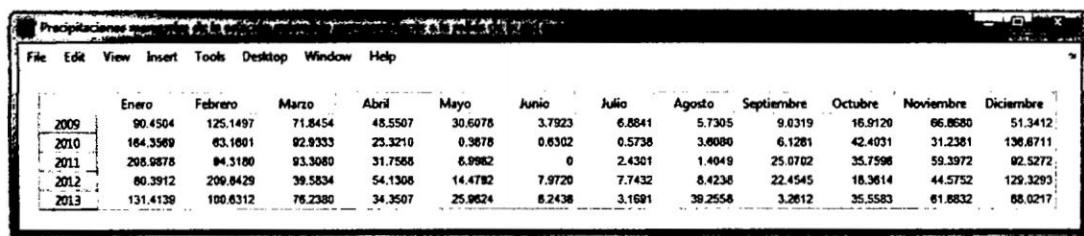


Fuente: Elaboración Propia.

## B.5. Resultados

Los resultados relacionados a la salida de la Red Neuronal se muestran al hacer click en los botones Mostrar y Trazar (lado izquierdo), para obtener valores en forma tabular y gráfica de la serie de tiempo; tal como se muestra en las figuras B.10 y B.11. De la misma manera los resultados relacionados al algoritmo 3B43 V7 del TRMM se muestran al hacer click en los botones Mostrar y Trazar (lado derecho); tal como se muestra en las figuras B.12 y B.13. Por último al hacer click en el botón Trazar (parte central) se muestra un gráfico comparativo de las precipitaciones mensuales obtenidas a partir de la Salida de la Red Neuronal y del algoritmo 3B43 V7 del TRMM, como se ve en la figura B.14.


**Figura B.10:** Precipitaciones mensuales tabuladas (Salida de la Red).



	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
2009	90.4504	125.1497	71.8454	48.5507	30.6078	3.7923	6.8841	5.7305	9.0319	16.9120	66.8680	51.3412
2010	164.3569	63.1601	82.9333	23.3210	0.3878	0.6302	0.5738	3.6080	6.1261	42.4031	31.2361	136.6711
2011	208.9878	84.3180	93.3080	31.7558	6.9962	0	2.4301	1.4049	25.0702	35.7598	59.3972	92.5272
2012	60.3912	209.8429	39.5834	54.1308	14.4782	7.9720	7.7432	8.4238	22.4545	18.3614	44.5752	129.3293
2013	131.4139	100.6312	78.2380	34.3507	25.9824	8.2438	3.1691	39.2558	3.2612	35.5583	61.8832	88.0217

Fuente: Elaboración Propia.

**Figura B.11:** Serie Temporal de precipitaciones mensuales (Salida de la Red).




Fuente: Elaboración Propia.

Figura B.12: Precipitaciones mensuales tabuladas (TRMM).

	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
2009	113.9630	172.3130	114.4078	104.0990	37.6143	10.1245	16.6350	52.3878	40.8523	63.9543	60.9438	82.2513
2010	155.5940	75.9840	140.6390	54.1633	44.3207	8.0093	21.1814	38.9631	34.8467	86.5043	44.9477	103.7980
2011	131.3240	160.4510	234.4430	84.5714	38.7978	1.6459	31.1045	16.0018	45.3819	57.4980	113.9960	148.0290
2012	135.2180	172.7160	118.2520	69.9031	14.6823	15.9119	22.8793	43.6476	73.4862	64.9423	82.2680	149.0470
2013	107.9640	129.9560	97.4443	48.4168	21.4857	8.8660	30.1145	44.4543	71.8208	73.9596	82.2263	137.9450


Fuente: Elaboración Propia.

Figura B.13: Serie Temporal de precipitaciones mensuales (TRMM).



Fuente: Elaboración Propia.

Figura B.14: Serie Temporal de precipitaciones mensuales (Salida de la Red y TRMM).



Fuente: Elaboración Propia.

## Apéndice C

# M-Files utilizados en el estudio de Validación

### C.1. Código de la función para la rotación de las abcisas en las Gráficas de Series Temporales.

---

```
1 % Función modificada a partir de la versión xticklabel_rotate90 desarrollada
2 % por Denis Gilbert.
3 % hText = xticklabel_rotate(XTick,rot,XTickLabel,varargin).
4 % Sintaxis: xticklabel_rotate.
5 % Ingreso:
6 % {opcional} XTick - arreglo de vectores de posiciones XTick &
7 % utiliza valores (numéricos) actuales Xtick o matriz de celdas XTickLabel
8 % por defecto (si está vacía).
9 % {opcional} rot - ángulo de rotación en grados, 90 por defecto.
10 % {opcional} XTickLabel - arreglo de celdas de cadenas de etiquetas.
11 % {opcional} [var] - "Propiedad-valor" pares pasan al generador de←
    texto.
12 % Salida: hText - manejar vector a etiquetas de texto.
13 function hText = xticklabel_rotate(XTick,rot,varargin)
14 if isempty(get(gca,'XTickLabel')),
15     error('xticklabel_rotate : can not process, either xticklabel_rotate has←
        already been run or XTickLabel field has been erased');
16 end
17 if (nargin < 3 || isempty(varargin{1})) & (~exist('XTick') | isempty(XTick))
18     xTickLabels = get(gca,'XTickLabel');
19     if ~iscell(xTickLabels)
20         templ = num2cell(xTickLabels,2);
21         for loop = 1:length(templ),
22             templ{loop} = deblank(templ{loop});
23         end
24         xTickLabels = templ;
25     end
```

```

26 varargin = varargin(2:length(varargin));
27 end
28 if (~exist('XTick') | isempty(XTick)),
29     XTick = get(gca,'XTick');
30 end
31 XTick = XTick(:);
32
33 if ~exist('xTickLabels'),
34     if (length(varargin)>0) & (iscell(varargin{1})),
35         xTickLabels = varargin{1};
36         varargin = varargin(2:length(varargin));
37     else
38         xTickLabels = num2str(XTick);
39     end
40 end
41 if length(XTick) ~= length(xTickLabels),
42     error('xticklabel_rotate : must have same number of elements in "XTick" ←
         and "XTickLabel"');
43 end
44 set(gca,'XTick',XTick,'XTickLabel','')
45 if nargin < 2,
46     rot = 90;
47 end
48 hxLabel = get(gca,'XLabel');
49 xlabelString = get(hxLabel,'String');
50 set(hxLabel,'Units','data');
51 xlabelPosition = get(hxLabel,'Position');
52 y = xlabelPosition(2);
53 y= repmat(y,size(XTick,1),1);
54 fs = get(gca,'fontsize');
55 hText = text(XTick, y, xTickLabels,'fontsize',fs);
56 xAxisLocation = get(gca, 'XAxisLocation');
57 if strcmp(xAxisLocation,'bottom')
58     set(hText,'Rotation',rot,'HorizontalAlignment','right',varargin{:})
59 else
60     set(hText,'Rotation',rot,'HorizontalAlignment','left',varargin{:})
61 end
62 set(get(gca,'xlabel'),'units','data');
63 labxorigpos_data = get(get(gca,'xlabel'),'position');
64 set(get(gca,'ylabel'),'units','data');
65 labyorigpos_data = get(get(gca,'ylabel'),'position');
66 set(get(gca,'title'),'units','data');
67 labtorigpos_data = get(get(gca,'title'),'position');
68 set(gca,'units','pixel');
69 set(hText,'units','pixel');
70 set(get(gca,'xlabel'),'units','pixel');
71 set(get(gca,'ylabel'),'units','pixel');
72 origpos = get(gca,'position');
73 x = get( hText, 'extent' );
74 if iscell( x ) == true
75     textsizes = cell2mat( x );
76 else
77     textsizes = x;
78 end
79 largest = max(textsizes(:,3));
80 longest = max(textsizes(:,4));
81 laborigext = get(get(gca,'xlabel'),'extent');

```

```

82 laborigpos = get(get(gca,'xlabel'),'position');
83 labyorigext = get(get(gca,'ylabel'),'extent');
84 labyorigpos = get(get(gca,'ylabel'),'position');
85 leftlabdist = labyorigpos(1) + labyorigext(1);
86 leftpos = get(hText(1),'position');
87 lefttext = get(hText(1),'extent');
88 leftdist = leftpos(1) + lefttext(1);
89 if leftdist > 0, leftdist = 0; end
90 if strcmp(xAxisLocation,'bottom')
91     newpos = [origpos(1)-(min(leftdist,labyorigpos(1)))+labyorigpos(1)←
origpos(2)+((longest+laborigpos(2))-get(gca,'FontSize'))origpos(3)-((←
min(leftdist,labyorigpos(1)))+labyorigpos(1)-largestorigpos(4)-((←
longest+laborigpos(2))-get(gca,'FontSize'))]
92 else
93     newpos = [origpos(1)-(min(leftdist,labyorigpos(1)))+labyorigpos(1)←
origpos(2)origpos(3)-(min(leftdist,labyorigpos(1)))+labyorigpos(1)-←
largestorigpos(4)-(longest)+get(gca,'FontSize')]
94 end
95 set(gca,'position',newpos);
96 set(hText,'units','data');
97 for loop= 1:length(hText),
98     set(hText(loop),'position',[XTick(loop), y(loop)]);
99 end
100 laborigpos = get(get(gca,'xlabel'),'position');
101 set(get(gca,'xlabel'),'position',[laborigpos(1) laborigpos(2)-longest 0]);
102 set(get(gca,'ylabel'),'units','data');
103 set(get(gca,'ylabel'),'position',labyorigpos_data);
104 set(get(gca,'title'),'position',labyorigpos_data);
105 set(get(gca,'xlabel'),'units','data');
106 labxorigpos_data_new = get(get(gca,'xlabel'),'position');
107 set(get(gca,'xlabel'),'position',[labxorigpos_data(1) labxorigpos_data_new←
(2)]);
108 set(get(gca,'xlabel'),'units','normalized');
109 set(get(gca,'ylabel'),'units','normalized');
110 set(get(gca,'title'),'units','normalized');
111 set(hText,'units','normalized');
112 set(gca,'units','normalized');
113 if nargin < 1,
114     clear hText
115 end

```

---

## C.2. Script para resolver un problema de ajuste usando el NFTOOL de MATLAB.

---

```

1 % Este Script Resuelve un problema de Ajuste de Ingreso - Salida con una
2 % Red Neuronal; elaborado por Miguel Raúl Guzmán Prado.
3 % Este script supone estas variables previamente definidas:
4 % TRMM - datos de ingreso.
5 % SENAMHI - datos objetivos.
6 inputs = TRMM;
7 targets = SENAMHI;

```

```

8 % Crea Una red de Ajuste.
9 hiddenLayerSize = 120;
10 net = fitnet(hiddenLayerSize);
11 % Seleccionar funciones de ingreso y salida para el Pre/Post -
12 % Procesamiento.
13 % Para una lista de todos los tipos de funciones de procesamiento: escriba
14 % en la línea de comandos help nnprocess.
15 net.inputs{1}.processFcns = {'removeconstantrows','mapminmax'};
16 net.outputs{2}.processFcns = {'removeconstantrows','mapminmax'};
17 % División de configuración de datos para el entrenamiento, validación y
18 % Para una lista de todos los tipos de funciones de división de datos:
19 % escriba en la línea de comando help nndivide.
20 net.divideFcn = 'dividerand'; % Divide datos aleatoriamente.
21 net.divideMode = 'sample'; % Divide cada muestra.
22 net.divideParam.trainRatio = 90/100;
23 net.divideParam.valRatio = 5/100;
24 net.divideParam.testRatio = 5/100;
25 % Para ayuda en el tipo de función de entrenamiento 'trainlm': escriba en
26 % la línea de comandos help trainlm.
27 % Para una lista de todos los tipos de las funciones de entrenamiento:
28 % escriba en la línea de comandos help nntrain.
29 net.trainFcn = 'trainlm'; % Función de entrenamiento Levenberg-Marquardt.
30 % Seleccionar una función de rendimiento.
31 % Para una lista de todos los tipos de las funciones de rendimiento:
32 % escriba en la línea de comandos help nnperformance.
33 net.performFcn = 'mse'; % Error cuadrático medio.
34 % Seleccionar funciones de trazado.
35 % Para una lista de todos los tipos de funciones de trazado: escriba en la
36 % línea de comandos help nnplot.
37 net.plotFcns = {'plotperform','plottrainstate','ploterrhist', ...
38 'plotregression', 'plotfit'};
39 % Entrenamiento de la Red.
40 [net,tr] = train(net,inputs,targets);
41 % Prueba de la Red.
42 outputs = net(inputs);
43 errors = gsubtract(targets,outputs);
44 performance = perform(net,targets,outputs)
45 % Recalcular el rendimiento del entrenamiento, Validación and Prueba.
46 trainTargets = targets .* tr.trainMask{1};
47 valTargets = targets .* tr.valMask{1};
48 testTargets = targets .* tr.testMask{1};
49 trainPerformance = perform(net,trainTargets,outputs)
50 valPerformance = perform(net,valTargets,outputs)
51 testPerformance = perform(net,testTargets,outputs)
52 % Ver la Red.
53 view(net)
54 % Trazados.
55 figure, plotperform(tr)
56 figure, plottrainstate(tr)
57 figure, plotfit(net,inputs,targets)
58 figure, plotregression(targets,outputs)
59 figure, ploterrhist(errors)

```

---

### C.3. M-File relacionado al programa PERC (Programa de extensión de precipitaciones mensuales sobre la Cuenca del Río Cachi).

---

```

1 function varargout = PERC(varargin)
2 gui_Singleton = 1;
3 gui_State = struct('gui_Name',       mfilename, ...
4                   'gui_Singleton',  gui_Singleton, ...
5                   'gui_OpeningFcn', @PERC_OpeningFcn, ...
6                   'gui_OutputFcn',  @PERC_OutputFcn, ...
7                   'gui_LayoutFcn',  [], ...
8                   'gui_Callback',   []);
9 if nargin && ischar(varargin{1})
10     gui_State.gui_Callback = str2func(varargin{1});
11 end
12
13 if nargout
14     [varargout{1:nargout}] = gui_mainfcn(gui_State, varargin{:});
15 else
16     gui_mainfcn(gui_State, varargin{:});
17 end
18 function PERC_OpeningFcn(hObject, eventdata, handles, varargin)
19 handles.output = hObject;
20 guidata(hObject, handles);
21 scrsz=get(0,'ScreenSize');
22 pos_act=get(gcf,'Position');
23 xr=scrsz(3)-pos_act(3);
24 xp=round(xr/2);
25 yr=scrsz(4)-pos_act(4);
26 yp=round(yr/2);
27 set(gcf,'Position',[0.1100*xp 0.02*yp pos_act(3) pos_act(4)]);
28 axes(handles.axes1)
29 [x,map]=imread('TRMM_Banner.jpg','jpg');
30 imshow(x),colormap(map),axis off, hold on;
31 axes(handles.axes2)
32 [x,map]=imread('logom.jpg','jpg');
33 imshow(x),colormap(map),axis off, hold on;
34 [a,map]=imread('calendario.jpg');
35 [r,c,d]=size(a);
36 x=ceil(r/100);
37 y=ceil(c/100);
38 g=a(1:x:end,1:y:end,:);
39 g(g==255)=5.5*255;
40 set(handles.pushbutton18,'CData',g);
41 function varargout = PERC_OutputFcn(hObject, eventdata, handles)
42 varargout{1} = handles.output;
43 function pushbutton1_Callback(hObject, eventdata, handles)
44 web http://disc2.nascom.nasa.gov/Giovanni/tovas/TRMM_V7.3B43.2.shtml -↔
45     browser
46 function pushbutton2_Callback(hObject, eventdata, handles)
47 winopen('TRMM.txt')
48 function pushbutton6_Callback(hObject, eventdata, handles)

```

```

48 global ai af Salida TRMM_NN
49 load net
50 load 'TRMM.txt'
51 TRMM_NN=TRMM(:,2)
52 matrix1=[1:12, 1:12, 1:12, 1:12, 1:12]
53 matrix2=[2009*ones(1,12), 2010*ones(1,12), 2011*ones(1,12), 2012*ones(1,12),←
2013*ones(1,12)]
54 Matrix=[matrix1;matrix2;TRMM_NN']
55 Salida=net(Matrix)
56 for i=1:length(Salida)
57     if Salida(1,i)<0
58         Salida(1,i)=0;
59     end
60 end
61 Aux3=zeros(5,12)
62 for i=1:5
63     Aux3(i,:)=Salida(:,(i-1)*12+1:12*i)
64 end
65 Aux3
66 aa=abs(str2num(ai))
67 bb=abs(str2num(af))
68 aData = {aa:bb}';
69 f = figure('Position',[275 200 1000 150],'Name','Precipitaciones mensuales ←
de la estación extendida correspondiente a la salida de la red (mm)', '←
NumberTitle','off');
70 cnames = {'Enero','Febrero','Marzo','Abril','Mayo','Junio','Julio','Agosto',←
'Septiembre','Octubre','Noviembre','Diciembre'};
71 rnames = {aData};
72 t = uitable('Parent',f,'Data',Aux3,'ColumnName',cnames,'RowName',rnames,'←
Position',[20 20 958 112]);
73 function pushbutton7_Callback(hObject, eventdata, handles)
74 global Salida
75 f = figure('Position',[200 200 1350 450],'Name','Serie Temporal de ←
Precipitaciones Mensuales de la Estación Extendida',...
76 'NumberTitle','off');
77 xi = datenum(2009,1:60,1);
78 plot(xi,Salida,'Color','b')
79 axis tight
80 set(gca,'Xtick',xi,'FontSize',9)
81 datetick('x','mmm yy','keepticks')
82 xticklabel_rotate([],90)
83 title('Serie Temporal de Precipitaciones Mensuales de la Estación Extendida'←
)
84 xlabel 'tiempo (Meses)'
85 ylabel 'Precipitación (mm/mes)'
86 hleg = legend('Salida de la Red Neuronal')
87 function pushbutton11_Callback(hObject, eventdata, handles)
88 global ai af
89 ai=get(handles.popupmenu2,'Value');
90 switch ai
91     case 1; ai='-2009'; case 2; ai='-2010'; case 3; ai='-2011';
92     case 4; ai='-2012'; otherwise; ai='-2013';
93 end
94 mi=get(handles.popupmenu3,'Value');
95 switch mi
96     case 1; mi='01'; case 2; mi='02'; case 3; mi='03'; case 4; mi='04';
97     case 5; mi='05'; case 6; mi='06'; case 7; mi='07'; case 8; mi='08';

```

```

98     case 9; mi='09'; case 10; mi='10'; case 11; mi='11'; otherwise; mi='12';
99 end
100 di=get(handles.popupmenu4,'Value');
101 switch di
102     case 1; di='-01'; case 2; di='-02'; case 3; di='-03'; case 4; di='-04';
103     case 5; di='-05'; case 6; di='-06'; case 7; di='-07'; case 8; di='-08';
104     case 9; di='-09'; case 10; di='-10'; case 11; di='-11';
105     case 12; di='-12'; case 13; di='-13'; case 14; di='-14';
106     case 15; di='-15'; case 16; di='-16'; case 17; di='-17';
107     case 18; di='-18'; case 19; di='-19'; case 20; di='-20';
108     case 21; di='-21'; case 22; di='-22'; case 23; di='-23';
109     case 24; di='-24'; case 25; di='-25'; case 26; di='-26';
110     case 27; di='-27'; case 28; di='-28'; case 29; di='-29';
111     case 30; di='-30'; otherwise; di='-31';
112 end
113 af=get(handles.popupmenu5,'Value');
114 switch af
115     case 1; af='-2009'; case 2; af='-2010'; case 3; af='-2011';
116     case 4; af='-2012'; otherwise; af='-2013';
117 end
118 mf=get(handles.popupmenu6,'Value');
119 switch mf
120     case 1; mf='01'; case 2; mf='02'; case 3; mf='03'; case 4; mf='04';
121     case 5; mf='05'; case 6; mf='06'; case 7; mf='07'; case 8; mf='08';
122     case 9; mf='09'; case 10; mf='10'; case 11; mf='11'; otherwise; mf='12';
123 end
124 df=get(handles.popupmenu7,'Value');
125 switch df
126     case 1; df='-01'; case 2; df='-02'; case 3; df='-03'; case 4; df='-04';
127     case 5; df='-05'; case 6; df='-06'; case 7; df='-07'; case 8; df='-08';
128     case 9; df='-09'; case 10; df='-10'; case 11; df='-11';
129     case 12; df='-12'; case 13; df='-13'; case 14; df='-14';
130     case 15; df='-15'; case 16; df='-16'; case 17; df='-17';
131     case 18; df='-18'; case 19; df='-19'; case 20; df='-20';
132     case 21; df='-21'; case 22; df='-22'; case 23; df='-23';
133     case 24; df='-24'; case 25; df='-25'; case 26; df='-26';
134     case 27; df='-27'; case 28; df='-28'; case 29; df='-29';
135     case 30; df='-30'; otherwise; df='-31';
136 end
137 function pushbutton12_Callback(hObject, eventdata, handles)
138 global ai af TRMM_NN TRMM_NN_1
139 load net
140 load 'TRMM.txt'
141 TRMM_NN=TRMM(:,2)
142 TRMM_NN_1=TRMM_NN'
143 Aux3=zeros(5,12)
144 for i=1:5
145     Aux3(i,:)=TRMM_NN_1(:,(i-1)*12+1:12*i)
146 end
147 Aux3
148 aa=abs(str2num(ai))
149 bb=abs(str2num(af))
150 aData = [aa:bb]';
151 f = figure('Position',[275 200 1000 150],'Name','Precipitaciones mensuales ←
    de la estación extendida correspondiente al TRMM (mm)','NumberTitle','off←
    ');

```

```

152 cnames = {'Enero','Febrero','Marzo','Abril','Mayo','Junio','Julio','Agosto',↵
    'Septiembre','Octubre','Noviembre','Diciembre'};
153 rnames = {aData};
154 t = uitable('Parent',f,'Data',Aux3,'ColumnName',cnames,'RowName',rnames,↵
    'Position',[20 20 958 112]);
155 function pushbutton13_Callback(hObject, eventdata, handles)
156 global TRMM_NN_1
157 f = figure('Position',[200 200 1350 450],'Name','Serie Temporal de ↵
    Precipitaciones Mensuales TRMM de la Estación Extendida',...
158 'NumberTitle','off');
159 xi = datenum(2009,1:60,1);
160 plot(xi,TRMM_NN_1,'Color','r')
161 axis tight
162 set(gca,'Xtick',xi,'FontSize',9)
163 datetick('x','mmm yy','kepticks')
164 xticklabel_rotate([],90)
165 title('Serie Temporal de Precipitaciones Mensuales TRMM de la Estación ↵
    Extendida')
166 xlabel 'tiempo (Meses)'
167 ylabel 'Precipitación (mm/mes)'
168 hleg = legend('Precipitación Mensual TRMM')
169 function pushbutton14_Callback(hObject, eventdata, handles)
170 global TRMM_NN Salida
171 f = figure('Position',[200 200 1350 450],'Name','Serie Temporal de ↵
    Precipitaciones Mensuales de la Estación Extendida',...
172 'NumberTitle','off');
173 xi = datenum(2009,1:60,1);
174 plot(xi,Salida,'Color','b')
175 hold on
176 plot(xi,TRMM_NN,'Color','r')
177 axis tight
178 set(gca,'Xtick',xi,'FontSize',9)
179 datetick('x','mmm yy','kepticks')
180 xticklabel_rotate([],90)
181 title('Serie Temporal de Precipitaciones Mensuales de la Estación Extendida'↵
    )
182 xlabel 'tiempo (Meses)'
183 ylabel 'Precipitación (mm/mes)'
184 hleg = legend('Salida de la Red Neuronal','Precipitación del TRMM')
185 function pushbutton18_Callback(hObject, eventdata, handles)
186 textH1 = uicontrol('style','edit','position',[10 10 100 20]);
187 uicalendar('DestinationUI',{textH1,'string'})
188 function uipushtool5_ClickedCallback(hObject, eventdata, handles)
189 web http://www.senamhi.gob.pe/ -browser
190 function uipushtool6_ClickedCallback(hObject, eventdata, handles)
191 web http://www.ign.gob.pe/ -browser
192 function uipushtool4_ClickedCallback(hObject, eventdata, handles)
193 web https://www.google.es/intl/es/earth/index.html -browser
194 function uipushtool3_ClickedCallback(hObject, eventdata, handles)
195 web http://www.mathworks.com/ -browser

```

---

## Apéndice D


### Fotografías

**Figura D.1:** Presa Cuchoquesera (Estructura Mayor de la Irrigación Cachi).



Fuente: Elaboración propia.

**Figura D.2:** Sifón Invertido de la Irrigación Cachi.




**Fuente:** Elaboración propia.

**Figura D.3:** Área Geográfica de la Irrigación Cachi.



**Fuente:** Elaboración propia.

**Figura D.4:** Bocatoma de la Irrigación Cachi.



**Fuente:** Elaboración propia.

**Figura D.5:** Válvulas de control de la Irrigación Cachi.



**Fuente:** Elaboración propia.

# Apéndice E

## Planos