

UNIVERSIDAD NACIONAL DEL ALTIPLANO
FACULTAD DE INGENIERÍA AGRÍCOLA
ESCUELA PROFESIONAL DE INGENIERÍA AGRÍCOLA



**“ESTIMACIÓN DE LA EVAPOTRANSPIRACIÓN DE REFERENCIA
UTILIZANDO MODELOS DE REDES NEURONALES ARTIFICIALES
EN FUNCIÓN DE ELEMENTOS CLIMÁTICOS EN
LA CUENCA DEL RIO HUANCANÉ”**

TESIS

PRESENTADA POR:

Br. LIANNE CADNIS MACHACA APAZA

PARA OPTAR EL TÍTULO DE:

INGENIERO AGRÍCOLA

PUNO - PERÚ

2016

UNIVERSIDAD NACIONAL DEL ALTIPLANO
FACULTAD DE INGENIERÍA AGRÍCOLA
ESCUELA PROFESIONAL DE INGENIERÍA AGRÍCOLA

TESIS

**“ESTIMACIÓN DE LA EVAPOTRANSPIRACIÓN DE REFERENCIA UTILIZANDO
MODELOS DE REDES NEURONALES ARTIFICIALES
EN FUNCIÓN DE ELEMENTOS CLIMÁTICOS EN
LA CUENCA DEL RIO HUANCANÉ”**

PRESENTADA POR:

Br. LIANNE CADNIS MACHACA APAZA

PARA OPTAR EL TÍTULO PROFESIONAL DE:

INGENIERO AGRÍCOLA

APROBADA POR EL JURADO CONFORMADO POR:

PRESIDENTE

:

Dr. EDUARDO FLORES CONDORI

PRIMER MIEMBRO

:

M.Sc. OSCAR RAÚL MAMANI LUQUE

SEGUNDO MIEMBRO

:

M.Sc. JOSÉ ANTONIO MAMANI GOMEZ

DIRECTOR DE TESIS

:

M.Sc. AUDBERTO MILLONES CHAFLOQUE

ASESOR DE TESIS

:

M.Sc. ROBERTO ALFARO ALEJO

ASESOR DE TESIS

:

Ing. YENIFFERD VELARDE CASTILLO

PUNO – PERÚ
2016

ÁREA : Ingeniería y Tecnología
TEMA: Modelamiento hidrológico
LÍNEA: Recursos Hídricos

DEDICATORIA

A mi madre. A la mujer que me dio dos grandes regalos: el primero, la vida y el segundo, la libertad para vivirla.

Con inconmensurable afecto a mis amigas de toda una vida a Aydee Oha, Janet Álvarez, Clorinda Chayña y Yenifferd Velarde, con ustedes he aprendido que no existe límites que todo lo que me proponga lo puedo lograr, con ustedes he aprendido a ser una mejor persona. Las considero mis mejores amigas y deseo que esta amistad perdure para siempre.

A mis hermanos menores Luis Germán y Manuel Lizandro, incansables amigos, por sus consejos y amistad.

Lianne Cadnis

AGRADECIMIENTO

- Antes que nada deseo expresar mi más sincera gratitud a mi maestro y director de tesis, al M.Sc. Audberto Millones Chafloque no sólo por su impecable labor de dirección sino también por sus continuas enseñanzas y apoyo en la elaboración de esta tesis. Por ofrecerme su disponibilidad y paciencia, por entender y saber guiar mis ideas. Mi más sincera gratitud por su generoso apoyo, confianza y amistad.
- Igualmente expreso mi agradecimiento a mi maestro al Ing. Teófilo Chirinos Ortiz, gracias por realizar esta investigación bajo tu orientación, por tutelar mi investigación, por darme todo y cuanto he necesitado. Todo esto ha sido un aporte invaluable y la clave del buen trabajo que hemos realizado. Mi más sincera gratitud por su apoyo y confianza.
- Al M.Sc. Roberto Alfaro Alejo asesor de tesis, por su acertado asesoramiento, cada comentario emanado de su experiencia sirvió verdaderamente para enriquecer mi trabajo.
- De manera muy especial, con admiración a mi amiga, a la Ing. Yenifferd Velarde Castillo asesora de tesis, por su preocupación y apoyo en la culminación de esta tesis, sobre todo por su infinita amistad.
- A los docentes de la Escuela Profesional de Ingeniería Agrícola, que con sus sabias enseñanzas contribuyeron en mi formación profesional.
- A nuestra alma mater, Universidad Nacional del Altiplano, por acogerme en sus claustros.
- Así también agradezco al Servicio Nacional de Meteorología e Hidrología - Puno por su valiosa colaboración de brindarme la información requerida en el desarrollo de esta tesis, sobre todo al Ing. Bernardino Tapia Aguilar y al Ing. Efraín Lujano Laura quienes a pesar de su apretada agenda siempre estuvieron dispuestos a brindarme sus discernimientos y su amistad.

Lianne Cadnis

INDICE

CONTENIDO	Pág.
Caratula	i
Índice.....	iv
Índice de cuadros.....	vii
Índice de figuras.....	x
Índice de graficos.....	xi
Índice de mapas.....	xii
Resumen.....	xiii
Abstract.....	xiv
Introducción.....	xv
CAPITULO I: PLANTEAMIENTO DEL PROBLEMA	1
1.1. FORMULACIÓN DEL PROBLEMA	1
1.1.1. Problema general	3
1.1.2. Problemas específicos.....	3
1.2. ANTECEDENTES.....	4
1.2.1. Antecedente internacional	4
1.2.2. Antecedente nacional	4
1.3. JUSTIFICACIÓN	5
1.4. OBJETIVOS.....	6
1.4.1. Objetivo general	6
1.4.2. Objetivos específicos.....	6
CAPITULO II: MARCO TEÓRICO Y CONCEPTUAL	7
2.1. MARCO TEÓRICO:	7
2.1.1. REDES NEURONALES ARTIFICIALES (RNA)	7
2.1.1.1. Definición de redes neuronales artificiales	7
2.1.1.2. Fundamento de las redes neuronales artificiales.....	8
2.1.1.3. Elementos de una red neuronal artificial	11
2.1.1.4. Funcionamiento de una RNA	14
2.1.1.5. Funciones de activación	15
2.1.1.6. Arquitectura de una RNA.....	19
2.1.1.7. Clasificación de Redes Neuronales Artificiales	22
2.1.1.8. Algoritmos de aprendizaje.....	26

2.1.2. MODELAMIENTO CON REDES NEURONALES ARTIFICIALES	31
2.1.2.1. Arquitectura	32
2.1.2.2. Entrenamiento.....	32
2.1.2.3. Validación y evaluación de modelos	33
a) Error cuadrático medio.....	33
b) Error cuadrático medio normalizado	34
c) Eficiencia de Nash y Sutcliffe	34
d) Coeficiente de determinación	35
d) Coeficiente de correlación.....	35
2.1.3. EVAPOTRANSPIRACIÓN DE REFERENCIA (ET _o)	37
2.1.3.1. Cultivo de referencia.....	38
2.1.4. ELEMENTOS METEOROLÓGICOS QUE DETERMINAN LA ET _o	39
2.1.4.1. Temperatura	39
2.1.4.2. Humedad relativa.....	39
2.1.4.3. Velocidad del viento.....	39
2.1.4.4. Radiación solar.....	40
2.1.5. MÉTODOS PARA ESTIMAR LA EVAPOTRANSPIRACIÓN DE REFERENCIA.....	40
2.1.5.1. MÉTODOS DIRECTOS.....	40
a) Métodos del lisímetro	40
b) Métodos del tanque de evaporación clase A	41
2.1.5.2. MÉTODOS INDIRECTOS.....	44
a) Método de FAO 56 Penman Monteith.....	44
a.1. Ecuación de FAO 56 Penman Monteith	44
a.2. Parámetros de la ecuación de FAO 56 Penman Monteith... 45	
b) Método de Hargreaves - Samani (1985).....	57
2.2. MARCO CONCEPTUAL:	58
2.2.1. Modelos.....	58
2.2.2. Redes Neuronales Artificiales.....	58
2.2.3. Evaporación	58
2.2.4. Transpiración.....	59
2.2.5. Evapotranspiración	59
2.2.6. Evapotranspiración potencial (ETP).....	59
2.2.7. Evapotranspiración de referencia (ET _o)	59
2.2.8. Evapotranspiración real (ET _r).....	60
2.2.9. Factor del cultivo (K _c).....	60
2.2.10. Necesidades de agua de riego	60

CAPITULO III: MATERIALES Y MÉTODOS	61
3.1. DESCRIPCIÓN DEL AMBITO DE ESTUDIO.....	61
3.1.1. Ubicación del ambito de estudio	61
3.1.1.1. Ubicación Geográfica	61
3.1.1.2. Ubicación Hidrográfica.....	61
3.1.1.3. Ubicación Política	61
3.1.1.4. Ubicación Administrativa.....	65
3.1.1.5. Vías de comunicación y acceso	66
3.1.2. Descripción General de la cuenca	66
3.1.3. Descripción Hidrográfica de la cuenca	67
3.1.4. Descripción Climática de la cuenca	69
3.2. MATERIALES	70
3.2.1. Información Cartográfica.....	70
3.2.2. Información Meteorológica	70
3.2.3. Equipos y Programas de cómputo.....	73
3.3. METODOLOGÍA.....	74
3.3.1. Tipo de investigación	74
3.3.2. Diseño de investigación	74
3.3.3. Variables.....	74
3.3.4. Población y Muestra	75
3.3.5. Técnicas e instrumentos.....	75
3.3.6. Procesamiento de información recopilada.....	76
3.3.7. Diagrama de flujo de la investigación	76
CAPITULO IV: RESULTADOS Y DISCUSIÓN	78
4.1. DELIMITACIÓN HIDROGRÁFICA DE LA CUENCA	78
4.2. ANALISIS EXPLORATORIO DE LA INFORMACIÓN METEOROLÓGICA	79
4.3. ESTIMACIÓN DE LA EVAPOTRANSPIRACIÓN DE REFERENCIA	85
4.4. MODELAMIENTO DE REDES NEURONALES ARTIFICIALES	85
4.4.1. Arquitectura.....	87
4.4.1.1. Planteamiento de modelos	87
4.4.2. Entrenamiento de modelos.....	92
4.4.3. Validación de modelos.....	93
4.4.3.1. Resultdos fase de validación	93
4.5. EVALUACIÓN Y SELECCIÓN DE MODELOS	110
4.5.1. Selección de modelos con variables similares a FAO 56 Penman Monteith	110
4.5.2. Selección de modelos con variables similares a Hargreaves – Samani (1985).....	111
4.5.3. Selección de modelos con variables similares al tanque clase A.....	111
4.6. ESTIMACIÓN DE LA EVAPOTRANSPIRACIÓN DE REFERENCIA	112
4.7. ANÁLISIS COMPARATIVO DE LA ET _o ESTIMADA CON RNA Y MÉTODOS EMPÍRICOS	113
CAPITULO V: CONCLUSIONES Y RECOMENDACIONES	119
5.1. CONCLUSIONES	119
5.1. RECOMENDACIONES	120
BIBLIOGRAFÍA.....	121

ÍNDICE DE CUADROS

CONTENIDO	Pág.
Cuadro N° 2.1: Funciones de activación	18
Cuadro N° 2.2: Tipos de RNA con aprendizaje supervisado	29
Cuadro N° 2.3: Tipos de RNA con aprendizaje no supervisado	30
Cuadro N° 2.4: Coeficientes k_p para el tanque clase A	43
Cuadro N° 3.1: Vías de acceso.	66
Cuadro N° 3.2: Unidades hidrográficas de la cuenca río Huancané.	68
Cuadro N° 3.3: Total de usuarios de Riego en la cuenca Huancané.	68
Cuadro N° 3.4. Estaciones meteorológicas de la cuenca Huancané y cuencas vecinas.....	71
Cuadro N° 3.5. Estaciones meteorológicas de la cuenca Huancané.	71
Cuadro N° 3.6. Periodo de registro de información meteorológica de Temperaturas Mínimas.	71
Cuadro N° 3.7. Periodo de registro de información meteorológica de Temperaturas Máximas.	72
Cuadro N° 3.8. Periodo de registro de información meteorológica de Velocidad del Viento.....	72
Cuadro N° 3.9. Periodo de registro de información meteorológica de Horas sol.	72
Cuadro N° 3.10. Periodo de registro de información meteorológica de Evaporación.	72
Cuadro N° 4.1: Cuartiles para datos de la estación Huancané.	79
Cuadro N° 4.2: Cuartiles para datos de la estación Putina.	81
Cuadro N° 4.3: Cuartiles para datos de la estación Muñani.	83
Cuadro N° 4.4: Distribución de datos para la estación Huancané.	86
Cuadro N° 4.5: Distribución de datos para la estación Putina.	86
Cuadro N° 4.6: Distribución de datos para la estación Muñani.	86
Cuadro N° 4.7: Planteamientos de modelos de RNA con variables de entrada similares al método FAO 56 Penman Monteith.....	88
Cuadro N° 4.8: Planteamientos de modelos de RNA con variables de entrada similares al método Hargreaves – Samani (1985)	89
Cuadro N° 4.9: Modelos de RNA con variables de entrada similares al método del Tanque de evaporación clase A.....	89
Cuadro N° 4.10: Características principales para el entrenamiento de RNA.	93
Cuadro N° 4.11: Estadísticos de la Fase de Validación de modelos de RNA con 5 - 4 variables comparados con el Método FAO 56 Penman Monteith.	94
Cuadro N° 4.12: Estadísticos de la Fase de Validación de modelos de RNA con 3 variables comparados con el Método FAO 56 Penman Monteith.	94

Cuadro N° 4.13: Estadísticos de la Fase de Validación de modelos de RNA con 2 variables comparados con el Método FAO 56 Penman Monteith.94

Cuadro N° 4.14: Estadísticos de la Fase de Validación de modelos de RNA con 1 variables comparados con el Método FAO 56 Penman Monteith.95

Cuadro N° 4.15: Estadísticos de la Fase de Validación de modelos de RNA con 5 - 4 variables comparados con el Método FAO 56 Penman Monteith.96

Cuadro N° 4.16: Estadísticos de la Fase de Validación de modelos de RNA con 3 variables comparados con el Método FAO 56 Penman Monteith.96

Cuadro N° 4.17: Estadísticos de la Fase de Validación de modelos de RNA con 2 variables comparados con el Método FAO 56 Penman Monteith.96

Cuadro N° 4.18: Estadísticos de la Fase de Validación de modelos de RNA con 1 variables comparados con el Método FAO 56 Penman Monteith.97

Cuadro N° 4.19: Estadísticos de la Fase de Validación de modelos de RNA con 4 - 3 variables comparados con el Método Hargreaves - Samani (1985).98

Cuadro N° 4.20: Estadísticos de la Fase de Validación de modelos de RNA con 2 variables comparados con el Método Hargreaves - Samani (1985).98

Cuadro N° 4.21: Estadísticos de la Fase de Validación de modelos de RNA con 1 variables comparados con el Método Hargreaves - Samani (1985).98

Cuadro N° 4.22: Estadísticos de la Fase de Validación de modelos de RNA con 4 - 3 variables comparados con el Método Hargreaves - Samani (1985).100

Cuadro N° 4.23: Estadísticos de la Fase de Validación de modelos de RNA con 2 variables comparados con el Método Hargreaves - Samani (1985).100

Cuadro N° 4.24: Estadísticos de la Fase de Validación de modelos de RNA con 1 variables comparados con el Método Hargreaves - Samani (1985).100

Cuadro N° 4.25: Estadísticos de la Fase de Validación de modelos de RNA con 4 - 3 variables comparados con el Método Hargreaves - Samani (1985).102

Cuadro N° 4.26: Estadísticos de la Fase de Validación de modelos de RNA con 2 variables comparados con el Método Hargreaves - Samani (1985).102

Cuadro N° 4.27: Estadísticos de la Fase de Validación de modelos de RNA con 1 variables comparados con el Método Hargreaves - Samani (1985).102

Cuadro N° 4.28: Estadísticos de la Fase de Validación de modelos de RNA con 4 - 3 variables comparados con el Método del Tanque clase A.104

Cuadro N° 4.29: Estadísticos de la Fase de Validación de modelos de RNA con 2 variables comparados con el Método del Tanque clase A.104

Cuadro N° 4.30: Estadísticos de la Fase de Validación de modelos de RNA con 1 variables comparados con el Método del Tanque clase A.104

Cuadro N° 4.31: Estadísticos de la Fase de Validación de modelos de RNA con 4 – 3 variables comparados con el Método del Tanque clase A.	106
Cuadro N° 4.32: Estadísticos de la Fase de Validación de modelos de RNA con 2 variables comparados con el Método del Tanque clase A.	106
Cuadro N° 4.33: Estadísticos de la Fase de Validación de modelos de RNA con 1 variables comparados con el Método del Tanque clase A.	106
Cuadro N° 4.34: Estadísticos de la Fase de Validación de modelos de RNA con 4 – 3 variables comparados con el Método del Tanque clase A.	108
Cuadro N° 4.35: Estadísticos de la Fase de Validación de modelos de RNA con 2 variables comparados con el Método del Tanque clase A.	108
Cuadro N° 4.36: Estadísticos de la Fase de Validación de modelos de RNA con 1 variables comparados con el Método del Tanque clase A.	108
Cuadro N° 4.37: Selección de modelos con variables similares a FAO 56 Penman Monteith – Fase Validación.	110
Cuadro N° 4.38: Selección de modelos con variables similares a Hargreaves - Samani (1985) – Fase Validación.	111
Cuadro N° 4.39: Selección de modelos con variables similares al Tanque de Evaporación clase A – Fase Validación.	112
Cuadro N° 4.40: Comparación de estadísticos del modelo de RNA y método FAO 56 PM.	113

ÍNDICE DE FIGURAS

CONTENIDO	Pág.
Figura N° 2.1: Neurona biológica.	9
Figura N° 2.2: Neurona y Conexiones Sinápticas.	10
Figura N° 2.3: Modelo de neurona artificial.	10
Figura N° 2.4: Modelos de una neurona artificial.	12
Figura N° 2.5: Neurona artificial.	13
Figura N° 2.6: Estructura y funcionamiento de una neurona artificial.	15
Figura N° 2.7: Arquitectura de una Red Neuronal Artificial.	20
Figura N° 2.8: Arquitectura de una Red Neuronal Artificial.	21
Figura N° 2.9: Clasificación de las RNA.	22
Figura N° 2.10: Red neuronal artificial monocapa.	23
Figura N° 2.11: Red neuronal artificial multicapa.	24
Figura N° 2.12: (a): ANN no recurrente; (b): ANN recurrente.	25
Figura N° 2.13: Ciclo del aprendizaje supervisado.	27
Figura N° 2.14: Ciclo del aprendizaje no supervisado.	30
Figura N° 2.15: Evapotranspiración del cultivo de referencia.	37
Figura N° 2.16: Características del cultivo de referencia.	38
Figura N° 2.17: Casos de localización del tanque de evaporación.	42
Figura N° 2.18: Componentes de la radiación.	46
Figura N° 2.19: Factores de conversión para convertir la velocidad del viento.	53
Figura N° 3.1: Organigrama de la gestión del agua en la cuenca del río Huancané.	65
Figura N° 3.2: Diagrama de flujo de la investigación.	77
Figura N° 4.1: Arquitectura simplificada de modelos de RNA con entradas similares al método FAO Penman Monteith.	91

ÍNDICE DE GRÁFICOS

CONTENIDO	Pág.
Grafico N° 4.1: Diagrama de dispersión modelo de RNA - 1 con 5 variables comparado con FAO P-M – Fase de Validación.	95
Grafico N° 4.2: Diagrama de dispersión modelo de RNA - 3 con 4 variables comparado con FAO P-M – Fase de Validación.	95
Grafico N° 4.3: Diagrama de dispersión modelo de RNA - 1 con 5 variables comparado con FAO P-M – Fase de Validación.	97
Grafico N° 4.4: Diagrama de dispersión modelo de RNA - 4 con 4 variables comparado con FAO P-M – Fase de Validación.	97
Grafico N° 4.5: Diagrama de dispersión modelo de RNA - 31 con 4 variables comparado con Hargreaves - Samani (1985) – Fase de Validación.	99
Grafico N° 4.6: Diagrama de dispersión modelo de RNA - 34 con 3 variables comparado con Hargreaves - Samani (1985) – Fase de Validación.	99
Grafico N° 4.7: Diagrama de dispersión modelo de RNA - 31 con 4 variables comparado con Hargreaves - Samani (1985) – Fase de Validación.	101
Grafico N° 4.8: Diagrama de dispersión modelo de RNA - 32 con 3 variables comparado con Hargreaves - Samani (1985) – Fase de Validación.	101
Grafico N° 4.9: Diagrama de dispersión modelo de RNA - 31 con 4 variables comparado con Hargreaves - Samani (1985) – Fase de Validación.	103
Grafico N° 4.10: Diagrama de dispersión modelo de RNA - 33 con 3 variables comparado con Hargreaves - Samani (1985) – Fase de Validación.	103
Grafico N° 4.11: Diagrama de dispersión modelo de RNA - 46 con 4 variables comparado con el Método del Tanque de Evaporación claseA–Fase de Validación.	105
Grafico N° 4.12: Diagrama de dispersión modelo de RNA - 49 con 3 variables comparado con el Método del Tanque de Evaporación clase A – Fase de Validación.	105
Grafico N° 4.13: Diagrama de dispersión modelo de RNA - 46 con 4 variables comparado con el Método del Tanque de Evaporación clase A – Fase de Validación.	107
Grafico N° 4.14: Diagrama de dispersión modelo de RNA - 49 con 3 variables comparado con el Método del Tanque de Evaporación clase A – Fase de Validación.	107
Grafico N° 4.15: Diagrama de dispersión modelo de RNA - 46 con 4 variables comparado con el Método del Tanque de Evaporación clase A – Fase de Validación.	109
Grafico N° 4.16: Diagrama de dispersión modelo de RNA - 47 con 3 variables comparado con el Método del Tanque de Evaporación clase A – Fase de Validación.	109

Grafico N° 4.17: Diagrama de dispersión de ETo observada y RNA – 1 (Estación Huancané – año 2013).114

Grafico N° 4.18: Diagrama de dispersión de ETo observada y RNA – 6 (Estación Huancané – año 2013).114

Grafico N° 4.19: Comparación de modelos estimados con el método de FAO 56 P-M y modelos de RNA (Enero a Marzo - 2013).115

Grafico N° 4.20: Comparación de modelos estimados con el método de FAO 56 P-M y modelos de RNA (Octubre a Diciembre - 2013).116

Grafico N° 4.21: Comparación de modelos empíricos (Estación Huancané - Año 2010)...117

Grafico N° 4.22: Comparación de modelos de RNA - 6 (4 variables) con el método Hargreaves – Samani (1985) (Estación Muñani – Año 2013).118

ÍNDICE DE MAPAS

CONTENIDO	Pág.
Mapa N° 3.1: Ubicación Geográfica de la cuenca del Río Huancané.	62
Mapa N° 3.2: Ubicación Hidrográfica de la cuenca del río Huancané.	63
Mapa N° 3.3: Ubicación Política de la cuenca del Río Huancané.	64
Mapa N° 4.1: Delimitación hidrográfica de la cuenca del Río Huancané.	78

RESUMEN

La investigación se realizó en la cuenca del río Huancané, ubicado dentro de la región hidrográfica del lago Titicaca, el objetivo de la investigación fue estimar la evapotranspiración de referencia utilizando modelos de Redes Neuronales Artificiales en función de elementos climáticos, así mismo se estableció diferentes modelos de Redes Neuronales Artificiales (RNA) y se realizó el análisis comparativo de los resultados de la evapotranspiración de referencia (ET_o) estimada por los modelos de RNA con los métodos empíricos. La información meteorológica utilizada corresponde a datos diarios de tres estaciones meteorológicas de la cuenca del río Huancané, para lo cual se planteo 56 modelos con variables de entrada de (temperatura, velocidad del viento, humedad relativa y horas de sol) y siempre con una misma variable de salida (evapotranspiración de referencia). Para el entrenamiento se utilizó el 70% de datos, para la validación el 15% de datos y para la prueba el 15% de datos, así mismo para el entrenamiento se utilizó la arquitectura Perceptrón Multicapa (MLP) y el algoritmo “backpropagation”. Para determinar el desempeño de los modelos de Redes Neuronales Artificiales, frente a los métodos empíricos se utilizo indicadores estadísticos como: el error cuadrático medio (ECM), error cuadrático medio normalizado (ECMN), el coeficiente de determinación (R^2) y el coeficiente de correlación (r). Finalmente la investigación logro establecer cinco modelos de RNA en función de elementos climáticos con las mismas y menos variables que utiliza el método FAO 56 Penman Monteith. Los modelos RNA-1 (ET_o= f(T_{min}, T_{max}, HR, V_v, HS)), RNA-3 (ET_o= f(T_{min}, HR, V_v HS)), RNA-2 (ET_o = f(T_{max}, HR, V_v HS)), RNA-7 (ET_o= f(T_{max}, V_v, HS)) y RNA-6 (ET_o = f(T_{min}, T_{max}, HR, V_v)) presentaron un mejor desempeño con un porcentaje de ajuste de 93.13%, 86.73%, 84.40%, 83.90% y 83.64% respectivamente y con un coeficiente de correlación de 96.50%, 93.13%, 91.87%, 91.60% y 91.46% respectivamente. Por lo tanto se comprobó que los modelos de RNA en función de elementos climáticos muestran un mejor desempeño frente a los modelos de Hargreaves – Samani (1985) y Tanque de evaporación clase A.

Palabras clave: Modelo, Redes Neuronales Artificiales, evapotranspiración de referencia, FAO 56 Penman Monteith, Hargreaves – Samani (1985), Tanque de evaporación clase A.

ABSTRACT

The research was conducted in the basin Huancané river, located within the catchment area of Lake Titicaca, the objective of the research was to estimate the reference evapotranspiration using models Artificial Neural Networks depending on climatic elements, likewise it established different models of Artificial Neural Networks (ANN) and was realised comparative analysis of the results of the reference evapotranspiration (ET_o) estimated by models of ANN with the empirical methods. Meteorological information used corresponds to three weather stations of the basin Huancané river, it was Proposed 56 models with input variables (temperature, wind speed, relative humidity and hours of sunshine) and always with the same output variable (reference evapotranspiration). For training 70% of data was used to validate 15% of data and for the test 15% of data, likewise for the training was used the Multilayer Perceptron (MLP) architecture and was used the algorithm backpropagation. To determine the performance of Artificial Neural Networks models compared with empirical methods it was used statistical indicators as: the mean square error (MSE), the mean square error normalized (NMSE), the coefficient of determination (R²) and the correlation coefficient (r). To determine the performance of Artificial Neural Networks models compared with empirical methods it was used statistical indicators as: the mean square error (MSE), the mean square error normalized (NMSE), the coefficient of determination (R²) and the correlation coefficient (r). The models ANN-1 (ET_o= f(T_{min}, T_{max}, HR, V_v, HS)), ANN-3 (ET_o= f(T_{min}, HR, V_v HS)), ANN-2 (ET_o = f(T_{max}, HR, V_v HS)), ANN-7 (ET_o= f(T_{max}, V_v, HS)) y ANN-6 (ET_o = f(T_{min}, T_{max}, HR, V_v)) have better performance with adjustment percentage 93.13%, 86.73 %, 84.40 %, 83.90 % and 83.64 % respectively and with a coefficient correlation of 96.50 %, 93.13 %, 91.87 %, 91.60 % and 91.46 % respectively. Therefore it was found that ANN models based on climatic elements show a better performance against models Hargreaves -Samani (1985) and Class A evaporation tank.

Keywords: Model, Artificial Neural Networks, reference evapotranspiration, FAO 56 Penman Monteith , Hargreaves - Samani (1985), evaporation tank class A.

INTRODUCCIÓN

En la agricultura resulta importante conocer con cierto grado de anticipación algunas variables climáticas tal como la evapotranspiración de referencia (ET_o), variable primordial en la planeación y distribución del recurso agua en zonas de riego. La cantidad de agua requerida para compensar la pérdida por evapotranspiración del cultivo se define como necesidades hídricas del cultivo, sobreestimar la evapotranspiración ocasiona el desperdicio de grandes cantidades de agua, por otro lado subestimar la evapotranspiración repercute en estrés hídrico para las plantas. Por tanto es necesario conocer con precisión la ET_o el cual se calcula con datos de temperatura, humedad relativa, velocidad del viento y radiación solar, debido a que no todas estas variables están disponibles en algunas estaciones meteorológicas, tal como es el caso de la estación Muñani, de ahí se plantea utilizar modelos de Redes Neuronales Artificiales para estimar la ET_o, con las mismas o menos variables que usan los métodos FAO 56 Penman Monteith, Hargreaves – Samani (1985) y Tanque de evaporación clase A.

En últimas investigaciones se han demostrado que los modelos de Redes Neuronales Artificiales son una herramienta excelente, debido a su capacidad para estimar variables no lineales, es así que el objetivo del presente trabajo de investigación es estimar la evapotranspiración de referencia utilizando modelos de Redes Neuronales Artificiales (RNA) en función de elementos climáticos, resulta importante conocer la evapotranspiración de referencia con anticipación para estimar las necesidades de agua de los cultivos y realizar una planeación acertada de las laminas de riego para la distribución del recurso agua de manera adecuada en proyectos de riego.

CAPÍTULO I

PLANTEAMIENTO DEL PROBLEMA

1.1. FORMULACIÓN DEL PROBLEMA

El método FAO 56 Penman –Monteith es recomendado mundialmente como el único método estándar para la determinación de la evapotranspiración de referencia (ET_o), desafortunadamente algunas estaciones meteorológicas de la región Puno no cuentan con registros de algunas variables necesarias como radiación solar u horas de sol, velocidad del viento y humedad relativa, tal es el caso de la estación meteorológica de Muñani el cual no cuenta con registros de horas de sol el cual condiciona la estimación de la ET_o por el método FAO 56 Penman – Monteith, en consecuencia si no se cuenta con dicha información se procede a la utilización de otros métodos en función al número de datos disponibles, como el método de Hargreaves - Samani (1985) y Tanque de evaporación clase A.

El principal problema que presenta la cuenca del río Huancané es la ausencia de la estimación de la ET_o por el método FAO 56 Penman - Monteith recurriendo a otros métodos empíricos como el método de Hargreaves - Samani (1985) y Tanque de evaporación clase A, el cual podría traer como consecuencia sobreestimar la ET_o lo que conlleva al desperdicio de grandes cantidades de agua o subestimar la

ETo el cual repercute en el estrés hídrico para las plantas, afectando la productividad y rentabilidad de los cultivos.

En base a lo indicado y teniendo en cuenta que en los últimos años se han desarrollado investigaciones utilizando modelos de Redes Neuronales Artificiales (RNA), que han permitido tener una mejor estimación de la Evapotranspiración de referencia que los métodos empíricos Kumar *et al.* (2002), Zanetti *et al.* (2007) y Cervantes (2010).

La presente investigación estimara la evapotranspiración de referencia utilizando Modelos de Redes Neuronales Artificiales en función de elementos climáticos utilizando las mismas o menos variables de entrada que utilizan los métodos empíricos de FAO 56 Penman – Monteith, Hargreaves - Samani (1985) y Tanque de evaporación clase A. Por lo tanto los modelos de RNA servirán como una alternativa metodológica para estimar la evapotranspiración de referencia con menos variables de entrada que utilizan los métodos empíricos por lo que se podrá estimar las necesidades de agua de los cultivos para realizar una planificación acertada de los proyectos de riego.

Así mismo se realizara un análisis comparativo de la evapotranspiración de referencia (ETo) estimada por modelos de Redes Neuronales Artificiales con los métodos empíricos de FAO 56 Penman - Monteith, Hargreaves - Samani (1985) y Tanque de evaporación clase A.

Considerando lo mencionado se plantea las siguientes preguntas:

1.1.1. PROBLEMA GENERAL:

¿Cuál es la estimación de la evapotranspiración de referencia utilizando modelos de redes neuronales artificiales en función de elementos climáticos en la cuenca del río Huancané?

1.1.2. PROBLEMAS ESPECIFICOS:

- ¿Cuáles son los modelos basados en Redes Neuronales Artificiales en función de elementos climáticos que permitan estimar la evapotranspiración de referencia (ET_o) en la cuenca del río Huancané?.
- ¿Cuál es la estimación de la evapotranspiración de referencia (ET_o) utilizando modelos de Redes Neuronales Artificiales en función de elementos climáticos con las mismas o menos variables de entrada que los métodos empíricos en la cuenca del río Huancané?.
- ¿Cuál es el análisis comparativo de la evapotranspiración de referencia estimada por modelos de Redes Neuronales Artificiales con los métodos empíricos de FAO 56 Penman - Monteith, Hargreaves - Samani (1985) y Tanque de evaporación clase A en la cuenca del río Huancané?.

1.2. ANTECEDENTES

1.2.1. Antecedente Internacional

Según Cervantes (2010), “Redes Neuronales Artificiales para estimar y predecir variables climatológicas relacionadas con la evapotranspiración de referencia”. (Tesis de Doctorado). Universidad autónoma Chapingo, México, realizó una comparación de metodologías convencionales con modelos de RNA para estimar la evapotranspiración de referencia, en el cual concluyo que el modelos RNABR7 {Tmax, Tmin, Rn}, modelo de red neuronal artificial de base radial (RBF) con las variables de entrada de temperatura máxima, temperatura mínima y radiación neta es el modelo que mejor desempeño mostro en la estimación de la evapotranspiración de referencia con $R^2 = 97.20\%$ frente al método de Hargreaves (1985) con $R^2 = 87.50\%$.

1.2.2. Antecedente Nacional

Según Laqui (2013), “Estimación de la evapotranspiración de referencia ETo utilizando modelos de Redes Neuronales Artificiales en Llachahui”. (II simposio internacional del lago Titicaca - TDP). ALT - Puno - Perú, concluyo en que los modelos de redes neuronales artificiales mostraron un gran desempeño en la estimación de la ETo, siendo el modelo 15 $ETo = f(HS, Tmax, Tmin, HR, Vv)$ el que presenta mejor desempeño dentro de los modelos que utilizan cinco variables con una $r = 93.54\%$.

1.3. JUSTIFICACIÓN:

El avance de la ciencia y tecnología se ha caracterizado por constantes cambios, como causa de lo anterior las últimas investigaciones han buscado nuevos modelos más eficientes para resolver todo tipo de problemas. En la región de Puno y específicamente en la cuenca del río Huancané algunas estaciones meteorológicas no cuentan con datos completos que requieren los métodos empíricos para estimar la evapotranspiración de referencia (ET_o), es así que la presente investigación utilizara modelos de Redes Neuronales Artificiales que permitirá estimar la ET_o a partir de variables que dispongan las estaciones meteorológicas como: datos de temperatura mínima, temperatura máxima, humedad relativa, velocidad del viento y horas de sol.

Resulta costoso medir directamente la evapotranspiración de referencia (ET_o) con un lisímetro y al no contar con esta información es que se desarrollara nuevas metodologías de bajo costo como los modelos de Redes Neuronales Artificiales que permiten estimar la evapotranspiración de referencia (E_{to}) con las mismas o menos variables de entrada que utilizan los métodos empíricos.

El sector favorecido con el desarrollo de los modelos de RNA será el sector agropecuario; en muchos casos se ha subestimado o sobreestimado la lámina de riego aplicada a los cultivos debido a una mala estimación de la ET_o; afectando a la productividad de los cultivos el cual repercute en bajos ingresos que perjudica a las familias y a la sociedad. Los modelos de RNA estimaran la evapotranspiración de referencia ET_o, lo cual permitirá conocer con claridad las láminas de riego para incidir en una productividad agrícola rentable para mejorar la economía y calidad de vida de los agricultores de la cuenca del río Huancané.

1.4. OBJETIVOS:

1.4.1. OBJETIVO GENERAL:

Estimar la evapotranspiración de referencia utilizando modelos de Redes Neuronales Artificiales en función de elementos climáticos en la cuenca del río Huancané.

1.4.2. OBJETIVOS ESPECÍFICOS:

- Establecer modelos basados en Redes Neuronales Artificiales en función de elementos climáticos que permitan estimar la evapotranspiración de referencia en la cuenca del río Huancané.

- Estimar la evapotranspiración de referencia utilizando modelos de Redes Neuronales Artificiales en función de elementos climáticos con las mismas o menos variables de entrada que utilizan los métodos empíricos en la cuenca del río Huancané.

- Realizar un análisis comparativo de la evapotranspiración de referencia estimada por modelos de Redes Neuronales Artificiales con los métodos empíricos de FAO 56 Penman - Monteith, Hargreaves - Samani (1985) y Tanque de evaporación clase A en la cuenca del río Huancané.

CAPITULO II

MARCO TEÓRICO Y CONCEPTUAL

2.1. MARCO TEÓRICO:

2.1.1. REDES NEURONALES ARTIFICIALES

2.1.1.1 DEFINICIÓN DE REDES NEURONALES ARTIFICIALES (RNA)

Según Bertona (2005), las Redes Neuronales Artificiales (RNA) son modelos matemáticos que intentan reproducir el funcionamiento del sistema nervioso. Como todo modelo, realizan una simplificación del sistema real que simulan y toman las características principales del mismo para la resolución de una tarea determinada.

Para Bravo *et al.* (2004), las Redes Neuronales Artificiales se presentan como un nuevo modelo empírico (o del tipo “caja negra”). Son modelos matemáticos que intentan imitar el funcionamiento del cerebro humano, a su vez lo define como sistemas de ecuaciones, en general no lineales, interconectados en los que el resultado de una ecuación es el valor de entrada de otras encadenadas a ella a través de la red. Son consideradas como aproximadores universales de funciones y, por lo tanto, tendrían la capacidad de conseguir reproducir el comportamiento de cualquier función matemática.

Según Bonilla (1997), las Redes Neuronales Artificiales son redes interconectadas masivamente en paralelo de elementos simples y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico.

Según Narváz (2009), las Redes Neuronales Artificiales son modelos que representan una función no lineal, son capaces de modelar una tarea determinada adaptando los parámetros internos de la red mediante un proceso de aprendizaje.

2.1.1.2 FUNDAMENTO DE LAS REDES NEURONALES ARTIFICIALES

EL MODELO BIOLÓGICO:

Según Sifontes (2010), el cerebro humano puede ser visto como una entidad de procesamiento de información. Este recibe información de un entorno externo por medio de los sentidos y los procesa para formar modelos internos a partir de fenómenos externos. El cerebro es particularmente capaz de ajustar estos modelos, así como interpolarlos y extrapolarlos para adaptarse a nuevas situaciones con mayor agilidad que puede hacer que éste tome decisiones más confiables e incluso reconocimiento de patrones, entendimiento de conceptos y realización de predicciones a partir de una información parcial o incompleta.

Una neurona biológica está conformada por tres componentes principales: las dendritas, que se encargan de canalizar las señales de entrada o estímulos, las cuales son ponderadas por la fuerza de las conexiones, al cuerpo celular; un cuerpo celular que acumula las señales de entrada ponderadas y además procesa estas señales; y un axón que transmite la señal de salida a otras neuronas que están conectadas a éste. La Figura N° 2.1 ilustra una neurona biológica.

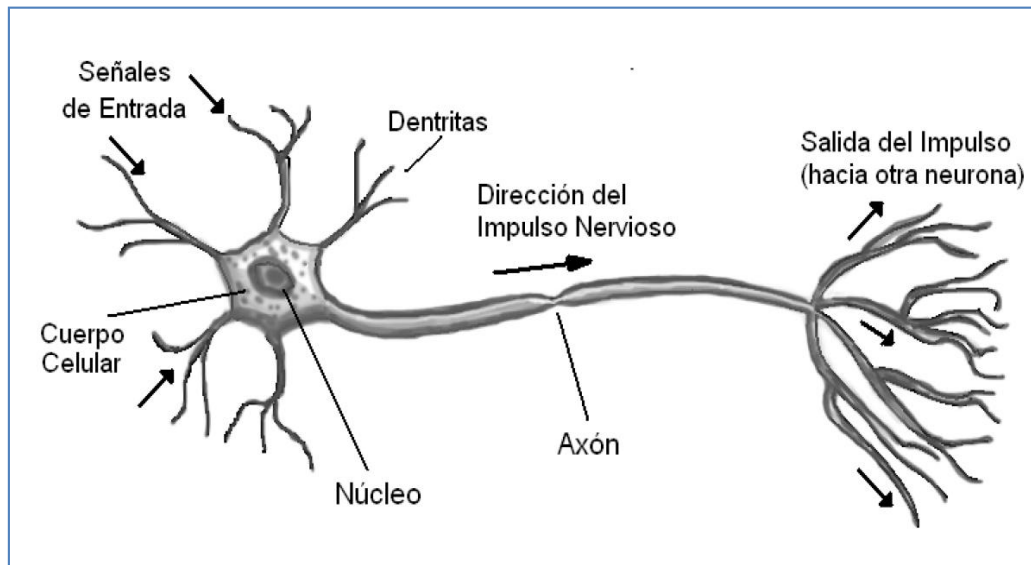


Figura N° 2.1: Neurona biológica.
Fuente: Sifontes (2010)

Según Hilera y Martínez (1995), la teoría y modelado de redes neuronales artificiales está inspirada en la estructura y funcionamiento de los sistemas nerviosos, donde la neurona es el elemento fundamental.

Una neurona es una célula viva y, como tal, contiene los mismos elementos que forman parte de todas las células biológicas. Además, contienen elementos característicos que las diferencian. Una de las características que diferencian a las neuronas del resto de las células vivas, es su capacidad de comunicarse. En términos generales, las dendritas y el cuerpo celular reciben señales de entrada; el cuerpo celular las combina e integra y emite señales de salida. El axón transporta esas señales a los terminales axónicos, que se encargan de distribuir información a un nuevo conjunto de neuronas.

Según Mateo (2012), lo que básicamente ocurre en una neurona biológica es lo siguiente: la neurona es estimulada o excitada a través de sus entradas (inputs) y cuando se alcanza un cierto umbral, la neurona se dispara o activa, pasando una señal hacia el axón.




Figura N° 2.2: Neurona y Conexiones Sinápticas.
Fuente: Vidaurre (2012)

EL MODELO DE NEURONA ARTIFICIAL:

Según Sifontes (2010), de la observación detallada del proceso llevado a cabo por neuronas biológicas se ha propuesto un modelo de neurona artificial que se muestra a continuación:

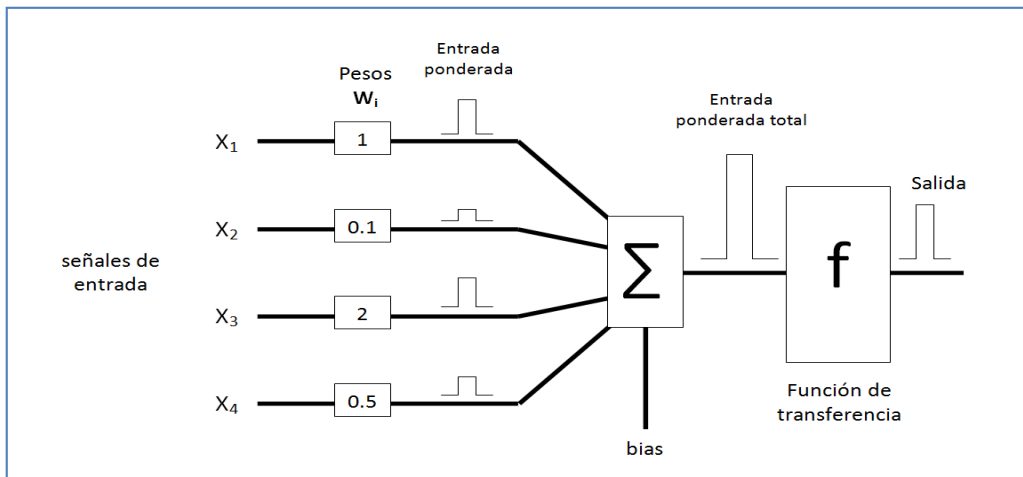


Figura N° 2.3: Modelo de neurona artificial.
Fuente: Sifontes (2010).

De este modelo se puede identificar tres elementos básicos:

Un grupo de sinapsis o enlaces interconexión.

Un sumador de señales de entrada ponderadas de acuerdo a sus respectivos pesos.

Una función de transferencia que limita la señal de salida.

En una neurona artificial las entradas X_i representan vectores o señales que provienen del exterior o son capturadas de otras neuronas. Los pesos W_i representan la intensidad de la sinapsis; tanto X_i como W_i son valores escalares. A esa señal ponderada se le adiciona el “**bias**”, que es un parámetro que permite polarizar convenientemente los datos de entrada y entonces se obtiene una entrada total que actúa sobre el núcleo de la neurona para activarla. La función f es la función de transferencia o función de activación que, evaluada para esa entrada total, produce la respuesta de la neurona al estímulo exterior recibido en forma similar a como ocurre en las células nerviosas biológicas.

En términos matemáticos este proceso se representa de forma sencilla como:

$$Salida = \int (X_{neta} + b)$$

$$X_{neta} = (X_1 \cdot W_1 + X_2 \cdot W_2 + X_3 \cdot W_3 + \dots + X_n \cdot W_n)$$

2.1.1.3 ELEMENTOS DE UNA RED NEURONAL ARTIFICIAL

Según Collantes (2001), una neurona artificial o nodo es una unidad de procesamiento de información que es fundamental para la operación de una red neuronal. En un modelo de una neurona pueden identificarse los siguientes elementos:

1. **Entradas o nodos de entrada:** son escalares que se le proporcionan a la red, de acuerdo al problema en estudio.
2. **Salidas o nodos de salida:** son los valores que arroja la red como resultado del aprendizaje.

3. **Un conjunto de pesos sinápticos o simplemente pesos:** son valores numéricos que expresa la importancia de la entrada correspondiente. El valor de la entrada X_i se dirige a la neurona K multiplicado por el peso W_{ik} . (El primer subíndice de los pesos se refiere a la entrada y el segundo a la neurona en cuestión).
4. **Un punto de suma de entradas ponderadas:** aquí se realiza la combinación lineal o suma de todas las entradas multiplicadas por sus correspondientes pesos.
5. **Una función de activación:** es una función, que puede ser lineal o no lineal, que limita el rango de la salida de la neurona.
6. **Sesgo:** es un valor formado por una entrada fija e igual a 1, denomina X_0 , multiplicada por el peso W_{0k} .

La Figura N° 2.4 ilustra en detalle el modelo de una neurona y, equivalentemente, la figura representa una forma más abreviada del mismo.

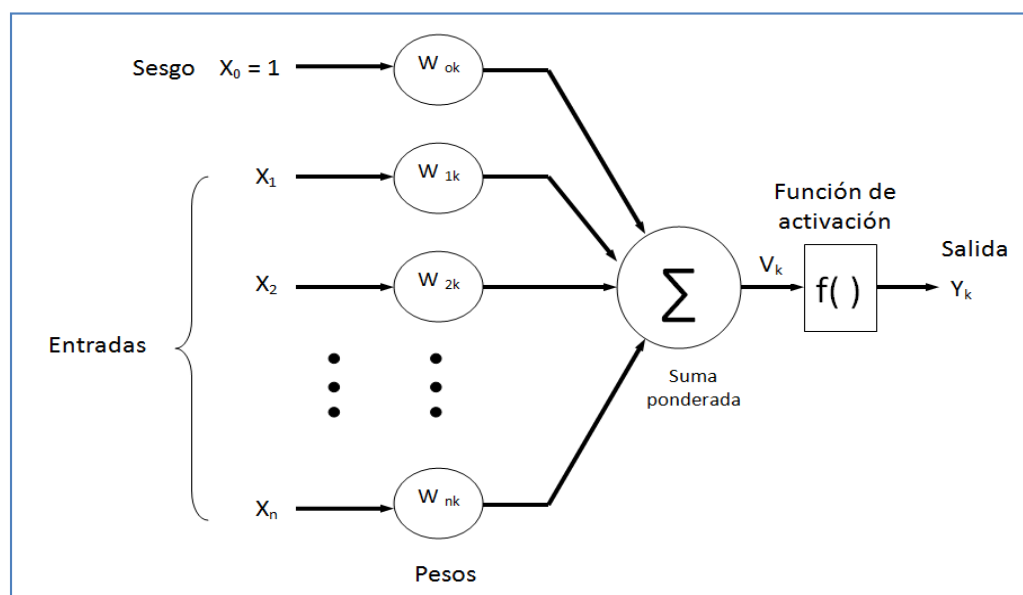


Figura N° 2.4: Modelos de una neurona artificial.
Fuente: Collantes (2001)

En la Figura N° 2.4 se puede observar que la neurona K puede describirse mediante las siguientes ecuaciones:

a) La acumulación:

$$V_k = \sum_{i=0}^n (X_i \cdot W_{ik})$$

b) La función de activación:

$$Y_k = f(V_k)$$

Donde $X_0, X_1, X_2, \dots, X_n$ son las entradas de la neurona K; $W_{0k}, W_{1k}, W_{2k}, \dots, W_{nk}$ son los pesos de la neurona K; V_k es la suma de las entradas multiplicadas por los pesos correspondientes; $f(.)$ es la función de activación y Y_k es la salida de la neurona K.

Los pesos son parámetros escalares que se van ajustando según la aplicación de una regla de aprendizaje de manera de cumplir con la relación entrada/salida y la función de activación se selecciona de acuerdo al objetivo del problema y al rango de valores en que se requiera la salida.

Según Bertona (2005), la neurona artificial es un elemento de procesamiento simple que a partir de un vector de entradas produce una única salida. La figura N° 2.5 muestra los elementos que componen una neurona artificial:

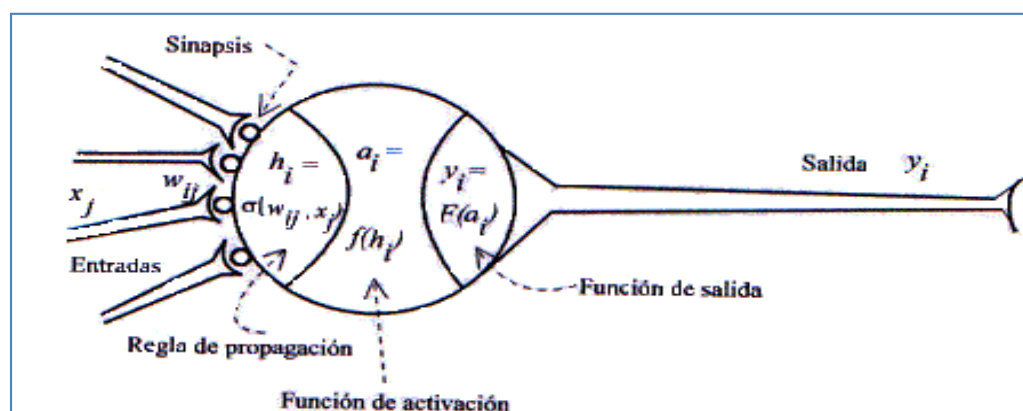


Figura N° 2.5: Neurona artificial.
Fuente: Bertona (2005).

1. **Conjunto de entradas, $x_j(t)$** : Estas pueden ser provenientes del exterior o de otras neuronas artificiales.
2. **Peso sinápticos, w_{ij}** : Representan el grado de comunicación entre la neurona artificial j y la neurona artificial i . Pueden ser excitadores o inhibidores
3. **Regla de propagación, $\sigma_i(w_{ij}, x_j(t))$** : Integra la información proveniente de las distintas neuronas artificiales y proporciona el valor del potencial postsináptico de la neurona i .
4. **Función de activación, $f_i(a_i(t-1), h_i(t))$** : Provee el estado de activación actual de la neurona i .
5. **Función de salida, $F_i(a_i(t))$** : Representa la salida actual de la neurona i .

2.1.1.4 FUNCIONAMIENTO DE UNA RNA

Según Hernández (2006), la neurona es el elemento que procesa la información en las RNA y juega un papel fundamental en su funcionamiento. El modo de operación de las neuronas es el siguiente:

1. El conjunto de entradas que llegan a la neurona j (X_j), será multiplicando por cada uno de los pesos (w_{ij}), asociado a las conexiones.
2. Se realizara una suma de esta ponderación de entradas con los pesos, junto con el valor del sesgo de la neurona (b_j).
3. Una vez obtenida esta suma ponderada, se obtiene la salida final al aplicar una función de activación propia de la neurona.

La ecuación que describiría el funcionamiento de los pesos para una neurona sería:

$$a_j = f(W_{j1} \cdot X_1 + W_{j2} \cdot X_2 + W_{j3} \cdot X_3 + \dots + W_{jR} \cdot X_R + b_j)$$

$$a_j = f[\sum_{i=1}^R (W_{ji} \cdot X_i) + b_j]$$

Siendo X_i la entrada procedente de la neurona i , W_{ji} el peso que modifica la entrada procedente de la neurona i y que va hasta la neurona j , b_j el sesgo correspondiente a la neurona actual j y a_j la salida de la neurona j actual. El modo de operación de una neurona artificial esta descrito de forma detallada en la Figura N° 2.6.

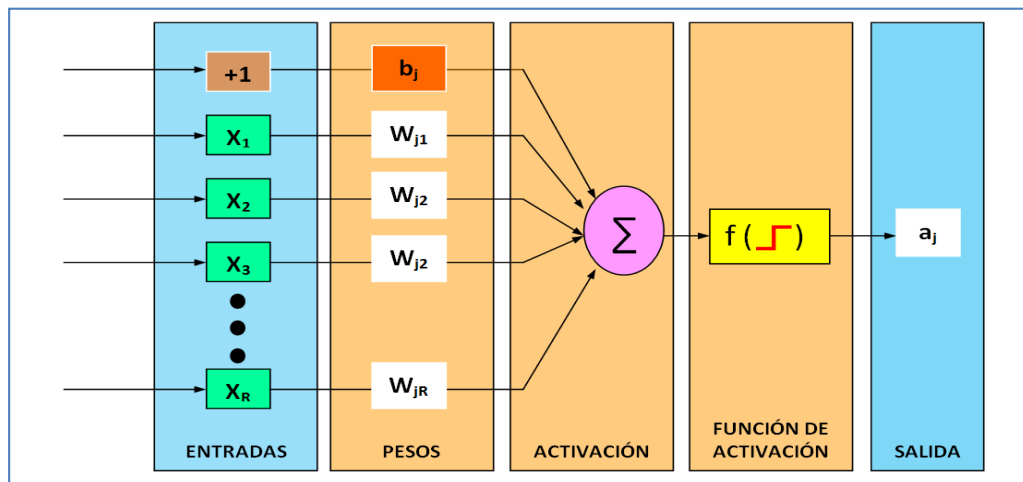



Figura N° 2.6: Estructura y funcionamiento de una neurona artificial.
Fuente: Hernández (2006).

2.1.1.5 FUNCIONES DE ACTIVACIÓN

Según Collantes (2001), la selección de la Función de Activación (FA) depende del criterio del investigador y del problema en estudio, en muchas ocasiones se selecciona por ensayo y error. Existen diversos tipos de FA, entre los más utilizados están.


1. **Función Escalón:** La salida de este tipo de FA puede ser 0 o 1, dependiendo si el parámetro de la función es positivo o negativo. Se usa para problemas de clasificación. En forma matemática puede expresarse como:

$$f(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases}$$




2. **Función Lineal:** La entrada de la FA es igual a la salida. Se usa en diversos tipos de redes, con frecuencia en la capa de salida. Su expresión es:

$$f(x) = x$$




3. **Función Logística:** Su salida comprende valores entre 0 y 1. Es la FA más usada en redes neuronales y se recomienda para problemas de predicción. Su expresión matemática es:

$$f(x) = \frac{1}{1 + e^{-x}}$$




4. **Función Tangente Hiperbólica:** Es semejante a la función logística, pero su salida está entre -1 y 1. Se utiliza con frecuencia en redes multicapas. En forma matemática se expresa como:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$




5. **Función Gaussiana:** Su rango está entre 0 y 1. Se utiliza en redes neuronales de función de base radial, las cuales pueden aplicarse a problemas de predicción. Su expresión matemática es:

$$f(x) = e^{-x^2}$$



6. **Función Sinusoidal:** Su rango está entre -1 y 1. Su expresión matemática es:

$$f(x) = \text{sen}(\omega \cdot x + \varphi)$$



Según Sifontes (2010), también es posible definir otras funciones de transferencia, el cuadro N° 2.1 resume las características de las funciones descritas anteriormente y otras que se han utilizado para caracterizar neuronas artificiales.

CUADRO N° 2.1: FUNCIONES DE ACTIVACIÓN

NOMBRE	RELACIÓN Entrada / Salida	GRÁFICA	FUNCIÓN
Escalón o Limitador Fuente	$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1 & \text{si } x \geq 0 \end{cases}$		hardlim
Escalón Simétrico	$f(x) = \begin{cases} -1 & \text{si } x < 0 \\ +1 & \text{si } x \geq 0 \end{cases}$		hardlims
Lineal Positiva	$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ x & \text{si } x \geq 0 \end{cases}$		poslin
Lineal	$f(x) = x$		purelin
Lineal Saturada	$f(x) = \begin{cases} 0 & x < 0 \\ x & 0 \leq x \leq 1 \\ 1 & x > 1 \end{cases}$		satlin
Lineal Saturada Simétrica	$f(x) = \begin{cases} -1 & x < -1 \\ x & -1 \leq x \leq 1 \\ +1 & x > 1 \end{cases}$		satlins
Sigmoidal Logística	$f(x) = \frac{1}{1 + e^{-x}}$		logsig
Sigmoidal Tangencial	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$		tansig

Fuente: Sifontes (2010).

2.1.1.6 ARQUITECTURA DE UNA RNA

Según Hilera y Martínez (1995), La topología o arquitectura de las redes neuronales consiste en la organización y disposición de las neuronas en la red, formando capas o agrupaciones de neuronas más o menos alejadas de la entrada y salida de dicha red. En este sentido, los parámetros fundamentales de la red son: el número de capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexiones entre neuronas.

Según Hernández (2006), Normalmente las neuronas se organizan en distintos niveles dentro de la red neuronal, que se suelen denominar capas. Estas capas se clasifican según su situación dentro de la red según el siguiente criterio.

1. **Capa de entrada:** Es siempre la primera capa de la RNA, y tiene tantas neuronas como entradas a la red. Cada neurona tiene pues una sola entrada que proviene directamente del exterior y varias salidas normalmente a neuronas de capas posteriores.
2. **Capas Ocultas:** Estas neuronas son las que realizan el trabajo y no tienen contacto directo con las señales externas a la red. Puede haber varias capas de neuronas ocultas, la primera de las capas ocultas estará conectada con la capa de entrada y la última de estas capas comunicará generalmente con la capa de salida. La forma de interconexión entre las distintas capas ocultas junto con el número de neuronas en cada capa determinará la topología de la red.

3. **Capa de Salida:** Es la capa de neuronas que transmite la información generada por la red al exterior. El número de neuronas de esta capa será igual al del número de salidas de la RNA.

La Figura N° 2.7 muestra un ejemplo de RNA multicapa con 3 entradas y 2 salidas y una capa oculta de 4 neuronas. En este caso específico, cada capa está totalmente interconectada con la siguiente, es decir, la salida de una neurona de una capa anterior llega a la entrada de todas las neuronas de la capa siguiente.

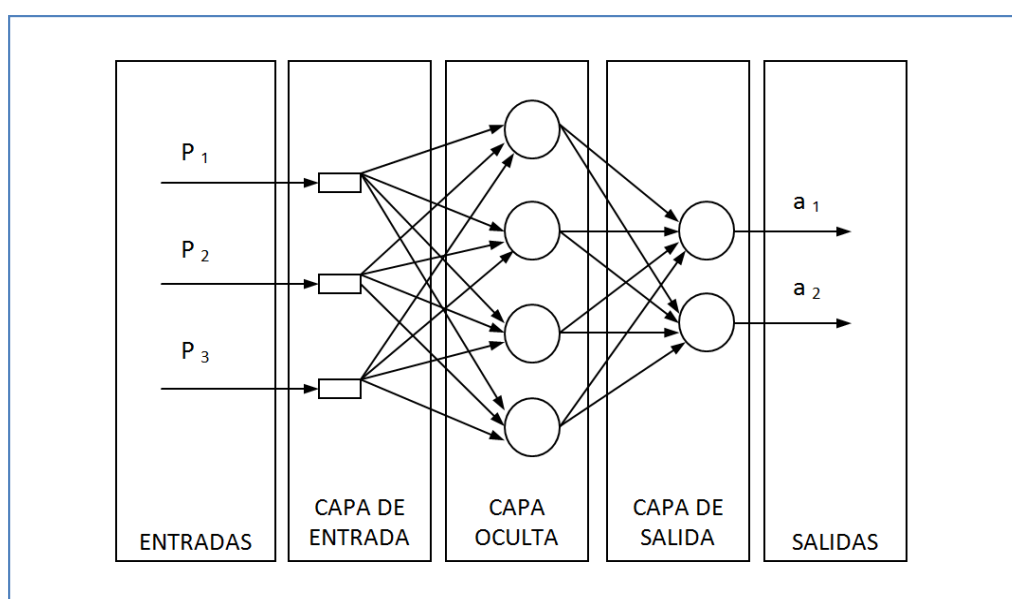


Figura N° 2.7: Arquitectura de una Red Neuronal Artificial.
Fuente: Hernández (2006).

Según Pino et al. (2001), para definir totalmente una red neuronal no basta con describir el comportamiento individual de sus componentes (neuronas), sino que hay que especificar también el interconexionado existente entre ellas. Estas se agrupan en capas, cada una de ellas con un conjunto de neuronas de número variable y comportamiento similar, constituyendo varias capas una red neuronal. Cada capa está conectada a la inmediata posterior total o parcialmente, excepto la última capa que constituye la salida total de la red neuronal. Existen tres tipos de capas:

1. **Capa de entrada:** El número y tipo de neuronas que constituyen esta capa, depende de los datos del problema.
2. **Capas intermedias:** Pueden ser más de una, dependiendo del tipo y complejidad del problema a resolver con la red. Mediante el tratamiento adecuado de estas capas se consiguen las propiedades de generalización, extracción de características, adaptabilidad, etc., que hacen muy interesante el trabajo de las redes neuronales.
3. **Capa de salida:** El número de neuronas de esta capa depende del formato esperado de salida de la red.

Las diferentes formas de distribuir, conectar e interrelacionar estos tres tipos de capas, junto al tipo de neuronas que constituyen cada una de ellas, nos va a definir los diferentes paradigmas de red existentes. Una arquitectura bastante común es la representada en la Figura N° 2.8.

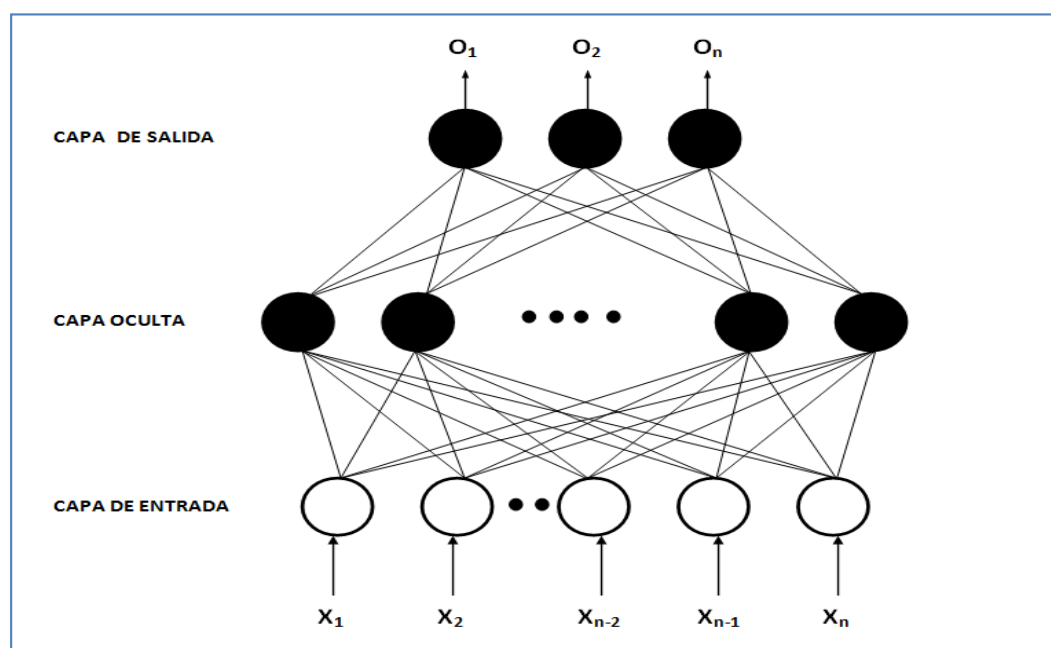


Figura N° 2.8: Arquitectura de una Red Neuronal Artificial.
Fuente: Pino et al. (2001).

2.1.1.7 CLASIFICACIÓN DE REDES NEURONALES ARTIFICIALES

Según Hernández (2006), la organización de las neuronas y el tipo de conexiones que existen entre ellas es lo que se denomina arquitectura de las RNA. La elección de la arquitectura óptima para cada aplicación específica a la que se quiera aplicar las RNA es un tema clave para encontrar una solución satisfactoria al problema a tratar.

Un posible esquema de la clasificación de las RNA en función de dichos parámetros aparece en la Figura N° 2.9. Como se puede observar en la figura, los parámetros fundamentales que determina la arquitectura de la RNA son el número de capas y la conectividad que se establece ente las neuronas. Tanto la nomenclatura de cada una de las RNA, como las diferentes subdivisiones dentro de estos dos criterios generales, se trata a continuación.

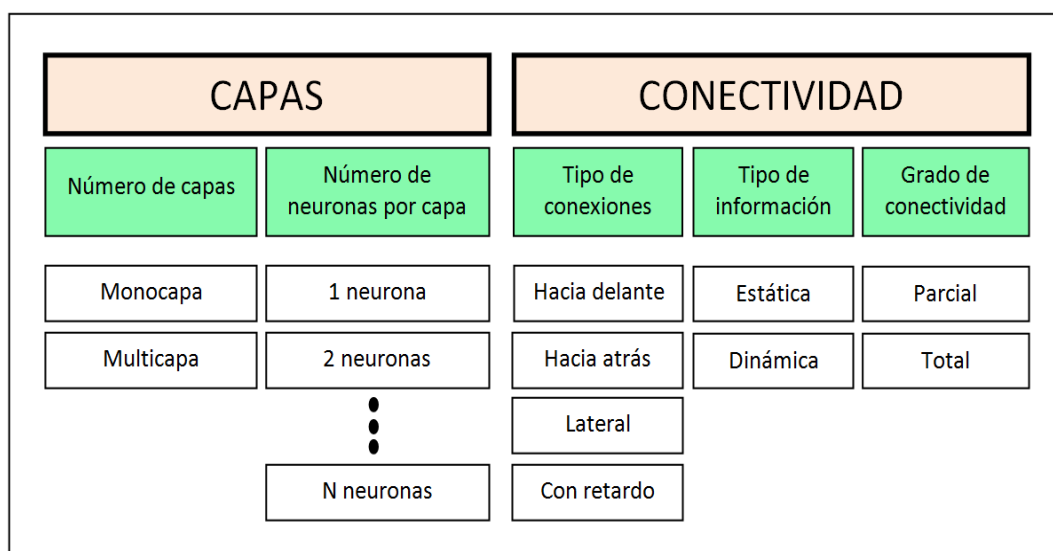


Figura N° 2.9: Clasificación de las RNA.
Fuente: Hernández (2006).

1. CLASIFICACIÓN SEGÚN EL NÚMERO DE CAPAS:

a. Redes monocapa:

Las redes monocapa solo cuentan con una capa de neuronas de entrada y una de salida, que intercambian señales con el exterior y que constituyen a un tiempo capa oculta y capa de salida del sistema. En las arquitecturas típicas de este tipo de red, las neuronas de entrada están totalmente interconectadas con las de salida, pero también existen casos donde las conexiones entre las neuronas son más complicadas. Por otra parte, los problemas que pueden ser resueltos por una red monocapa son bastante limitados, teniendo que recurrir en la mayoría de los casos a las redes multicapa.


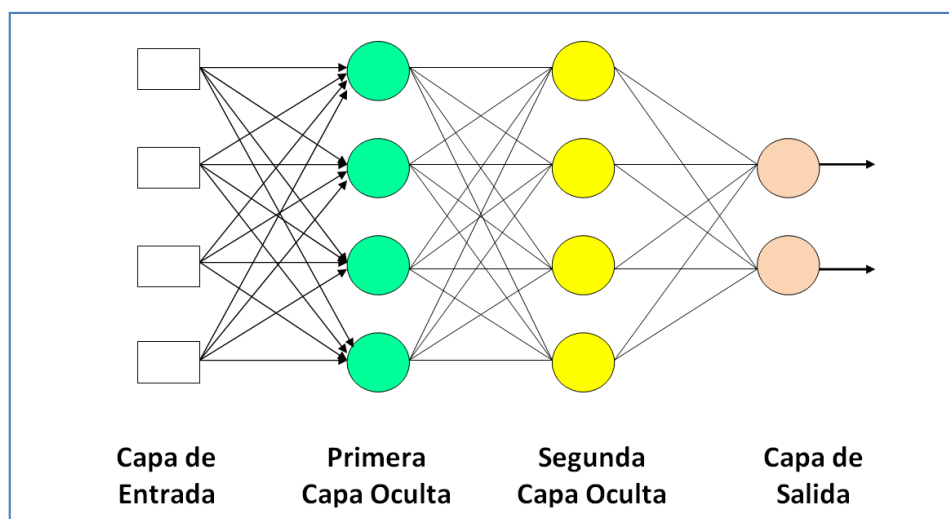


Figura N° 2.10: Red neuronal artificial monocapa.
Fuente: Catalán (2012).

b. Redes multicapa:

Las redes multicapa están compuestas por al menos una capa oculta entre la capa de entrada y la de salida de la RNA. Las redes multicapa pueden resolver problemas más complicados que las redes monocapa, a cambio eso sí, de tratar con superficies más complejas y un entrenamiento mucho más costoso y con más dificultades para evitar mínimos locales. Normalmente la dificultad del problema a resolver va asociado con el tamaño de las redes multicapa, que está definido por el número de capas ocultas y de neuronas en cada una de ellas.



Figura

Nº 2.11: Red neuronal artificial multicapa.
Fuente: Catalán (2012).

2. CLASIFICACIÓN SEGÚN EL TIPO DE CONEXIONES:

a. Conexiones hacia delante:

El sentido de transmisión de la información en este tipo de conexiones se realiza desde neuronas de capas inferiores (más cercanas a la capa de entrada) hacia neuronas de capas superiores (más cercanas a la salida). También se denominan *feedforward*.

b. Conexiones hacia atrás:

Estas conexiones llevan los datos de las neuronas de una capa superior, a otras de una capa inferior. Son también llamadas *feedbackward*.

c. Conexiones laterales:

Son las conexiones que se hacen entre neuronas de una misma capa. Estas conexiones se diseñan como excitadoras, permitiendo la cooperación (con peso positivo) o la inhibición (con peso negativo) entre neuronas, lo que establece una competición entre neuronas de la misma capa.

d. Conexiones con retardo:

Los elementos de retardo se incorporan en las conexiones para implementar modelos dinámicos temporales (redes dinámicas). Se almacenan datos antiguos para después procesarlos junto con la información actual.

e. Conexiones auto-recurrentes:

La salida de una neurona se conecta con su propia entrada.

f. Redes neuronales no recurrentes:

En esta red la propagación de las señales se produce en un sentido solamente, no existiendo la posibilidad de realimentaciones, por lo que no tienen memoria. La red de la Figura N° 2.12 es no recurrente.

g. Redes neuronales recurrentes:

Esta red viene caracterizada por la existencia de lazos de realimentación. La retroalimentación contiene un retraso que permite retener los valores del primer paso para usarlo en el posterior paso de procesamiento. De este modo la red puede grabar información como referencia futura e identificar patrones tanto temporales como espaciales.

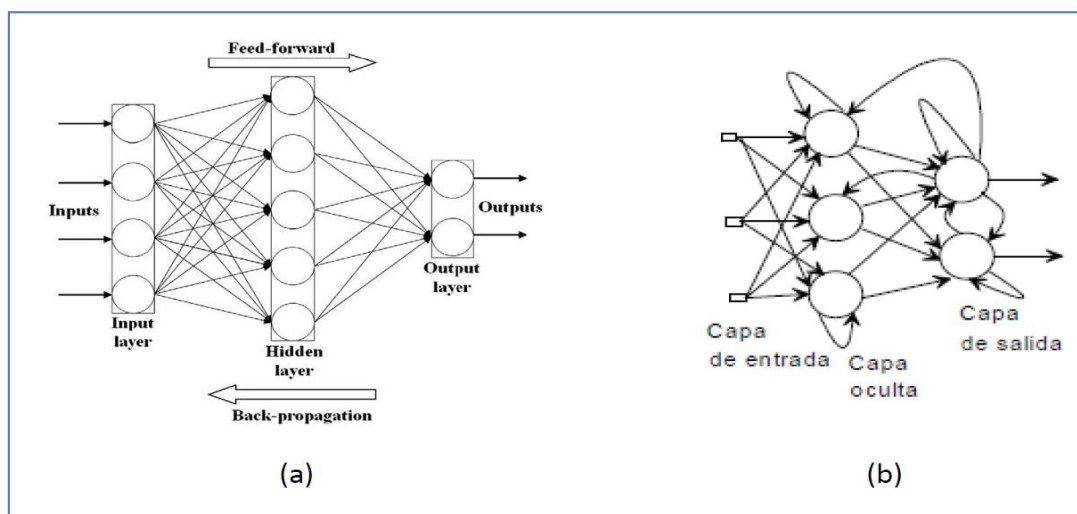


Figura N° 2.12: (a): ANN no recurrente; (b): ANN recurrente.
Fuente: Catalán (2012).

3. CLASIFICACIÓN SEGÚN EL TIPO DE INFORMACIÓN:

a. Redes neuronales estáticas:

El tipo de información que manejan las redes estáticas tiene carácter estacionario, es decir, el valor de la salida solo depende del valor de las entradas en el mismo momento en el que ésta se produce. Normalmente van asociadas a las redes con conexiones hacia adelante (*feedforward*).

b. Redes neuronales dinámicas:

La información que se maneja en este tipo de redes incluye la variable tiempo, es decir, la salida depende de las variables de entrada en el momento actual y de los valores de entrada y/o salida en momentos anteriores. Para incluir la variable tiempo, se puede incorporar en la red retardos temporales o conexiones de tipo *feedbackward* entre las capas de neuronas. El entrenamiento para las redes dinámicas puede plantear problemas de convergencia y estabilidad, y los resultados son en general de difícil análisis.

2.1.1.8 ALGORITMOS DE APRENDIZAJE

Según Flórez y Fernández (2008), existen dos tipos básicos de reglas de aprendizaje que pueden utilizarse para la actualización de los pesos: el aprendizaje supervisado y el aprendizaje no supervisado, cuya distinción procede del campo del reconocimiento de patrones. La diferencia fundamental entre ambos tipos radica en la existencia o no de un agente externo o supervisor, que controla el proceso de aprendizaje de la red.

1. APRENDIZAJE SUPERVISADO:

El aprendizaje supervisado se caracteriza por la presencia de un agente externo (supervisor o maestro) que controla el proceso de entrenamiento, estableciendo la respuesta de debería generar la red (output del sistema) a partir de una entrada determinada. De esta forma, el supervisor comprueba la salida de la red, la compara con la salida deseada y, si existen diferencias, ajusta iterativamente los pesos hasta que su salida tiende a ser la deseada, utilizando para ello información detallada del error cometido en cada paso.

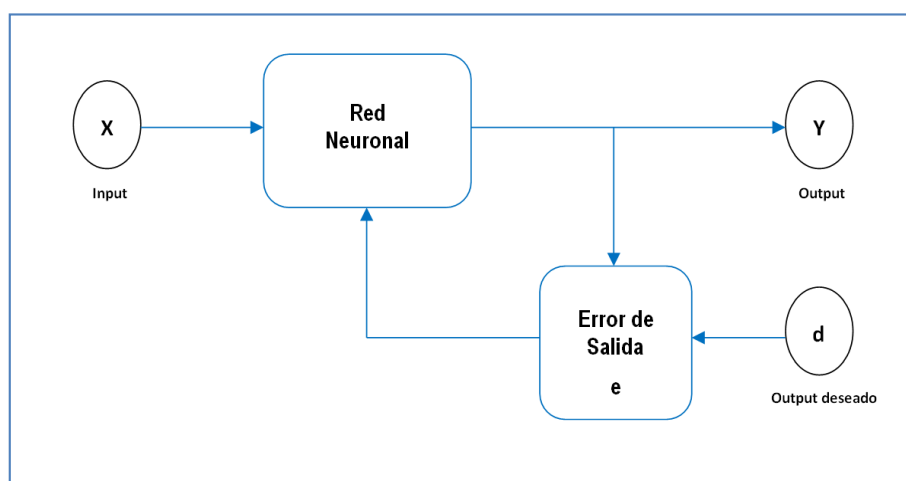


Figura N° 2.13: Ciclo del aprendizaje supervisado.
Fuente: Torra y Monte (2013).

Este tipo de aprendizaje permite distinguir tres tipos de aprendizaje supervisado: por corrección de error, por refuerzo o de tipo estocástico.

a. APRENDIZAJE POR CORRECCIÓN DE ERROR:

Consiste en ajustar los pesos de las conexiones de la red en función de la diferencia entre los valores deseados y los obtenidos en la salida de la red; es decir, en función del error cometido en la salida.

$$\Delta W_{ji} = \alpha \cdot x_i (t_j - y_j)$$

Donde ΔW_{ji} es la variación del peso que va de la neurona i hasta la j , α es el factor o tasa de aprendizaje que es mayor que cero, x_i es la salida de la neurona i , t_j es el valor deseado de la salida j y y_j es el valor obtenido por la red.

b. APRENDIZAJE POR REFUERZO:

En el aprendizaje por refuerzo la función del supervisor se reduce a indicar mediante una señal de refuerzo si la salida obtenida en la red se ajusta a la deseada (éxito = +1 o fracaso = -1), y en función de ello se ajustan los pesos basándose en un mecanismo de probabilidades. Se podría decir que en este tipo de aprendizaje la función del supervisor se asemeja más a la de un crítico (que opina sobre la respuesta de la red) que a la de un maestro (que indica a la red la respuesta concreta que debe generar), como ocurría en el caso de supervisión por corrección del error.

c. APRENDIZAJE ESTOCÁSTICO:

Consiste básicamente en realizar cambios aleatorios en los valores de los pesos de las conexiones de la red y evaluar su efecto a partir del objetivo deseado y de distribuciones de probabilidad. Según lo anterior, el aprendizaje consistiría en realizar un cambio aleatorio de los valores de los pesos y determinar la energía de la red. Si la energía es menor después del cambio; es decir, si el comportamiento de la red se acerca al deseado, se acepta el cambio. Si, por el contrario, la energía no es menor, se aceptaría el cambio en función de una determinada y preestablecida distribución de probabilidades.

CUADRO N° 2.2: Tipos de RNA con aprendizaje supervisado

TIPO DE APRENDIZAJE SUPERVISADO		MODELO DE RED
APRENDIZAJE POR CORRECCIÓN DE ERROR	off line	PERCEPTRON
		ADALINE/MADALINE
		BACKPROPAGATION
		BRAIN - STATE-IN-A-BOX
		COUNTERPROPAGATION
APRENDIZAJE POR REFUERZO	on line	LINEAR REWARD PENALTY
		ASSOCIATIVE REW, PENALTY
		ADAPTIVE HEURISTIC CRITIC
APRENDIZAJE ESTOCÁSTICO	off line	BOLTZMANN MACHINE
		CAUCHY MACHINE

Fuente: Hiler y Martínez (1995).

2. APRENDIZAJE NO SUPERVISADO:

Las redes con aprendizaje no supervisado (o “Autosupervisado”) no requieren información externa para ajustar los pesos de las conexiones entre sus neuronas. En el aprendizaje no supervisado se presenta a la red un conjunto de patrones sin adjuntar la respuesta deseada por lo que la red, por medio de algoritmos de aprendizaje, estima la función de densidad probabilística que describe la distribución de patrones. Para ello, el sistema reconoce las peculiaridades, correlaciones o categorías presentes en el conjunto de entradas, extrayendo rasgos o agrupando patrones según su similitud.

En otros casos, la RNA podría realizar una *clusterización* o establecimiento de categorías, tal que el output indicaría la categoría a la que pertenece la información presentada a la entrada. Asimismo, la red puede realizar tareas de obtención de prototipos, obteniendo ejemplares representativos de las clases a las que pertenecen las informaciones de entrada. Este tipo de aprendizaje permite distinguir dos tipos de aprendizaje no supervisado: aprendizaje hebbiano, aprendizaje competitivo y cooperativo.




Figura N° 2.14: Ciclo del aprendizaje no supervisado.
Fuente: Torra y Monte (2013).

a. .APRENDIZAJE HEBBIANO:

Consiste en el ajuste de los pesos de las conexiones de acuerdo con la correlación, así si las dos unidades son activas (positivas), se produce un reforzamiento de la conexión. Por el contrario cuando una es activa y la otra pasiva (negativa), se produce un debilitamiento de la conexión.

b. APRENDIZAJE COMPETITIVO Y COOPERATIVO:

Las neuronas compiten y cooperan unas con otras con el fin de llevar a cabo una tarea dada. Con este tipo de aprendizaje se pretende que cuando se presente a la red cierta información de entrada, solo una de las neuronas de salida se active, por lo tanto las neuronas compiten por activarse.

CUADRO N° 2.3: Tipos de RNA con aprendizaje no supervisado

TIPO DE APRENDIZAJE NO SUPERVISADO		MODELO DE RED
APRENDIZAJE HEBBIANO	Off line	HOPFIELD
		LEARNING MATRIX
		TEMPORAL ASSOC. MEMORY
		LINEAR ASSOCIATIVE MEMORY (LAM)
		OPTIMAL LAM
	On line	DRIVE-REINFORCEMENT
		FUZZY ASSOCIATIVE MEMORY
		ADDITIVE GROSSBERG
		SHUNTING GROSSBERG
		BIDIRECTIONAL ASSOCIATIVE MEMORY (BAM)
APRENDIZAJE COMPETITIVO Y COOPERATIVO	Off line	ADAPTIVE BAM
		LEARNING VECTOR QUANTIZER
		COGNITRON / NEOCOGNITRON
		TOPOLOGY PRESERVING MAP

Fuente: Hilera y Martínez (1995).

2.1.2. MODELAMIENTO CON REDES NEURONALES ARTIFICIALES

Según Barría (2010), los modelos de redes neuronales en el pronóstico suponen 2 dificultades; primero que al considerar una red interconectada existe un gran número de pesos que calibrar; y la segunda, es que cada neurona aporta con una función no lineal a los cálculos de la red lo que en general causa tiempos de procesamiento de datos altos, dada la alta no linealidad del sistema. La metodología en primer lugar requiere de la división de los datos en 3 grupos como se indica a continuación:

- Datos de Entrenamiento: corresponden al 50% de los datos.
- Datos de Validación: 25% de los datos.
- Datos de Prueba: 25% de los datos.

Posteriormente se sigue un proceso iterativo en que se definen las posibles arquitecturas de las redes, número de nodos y número de capas, que se logra a base de tanteos, es decir, prueba y error. A continuación se entrena la red y se valida con los conjuntos de datos definidos para estas labores. Finalmente se evalúa la red con el conjunto de prueba. Se finaliza realizando un pronóstico.

Las actividades anteriormente descritas se llevan a cabo iterativamente con distintas arquitecturas o configuraciones, de las cuales se escoge la que entregue mejores resultados, evaluados por los indicadores estadísticos que se explicitan en el siguiente punto.

Según Lujano (2010), menciona que ha optado por utilizar un número menor de ellos para la validación y prueba, dando un énfasis mayor al entrenamiento de la red, luego la división de datos se forma como se indica a continuación:

- Datos de Entrenamiento: 70% del total de datos.
- Datos de Validación : 15% del total de datos.
- Datos de Prueba : 15% del total de datos.

2.1.2.1. ARQUITECTURA:

Se puede elegir en este paso entre dos enfoques según se trate de predecir un solo concepto (múltiples entradas y una sola unidad de salida), la arquitectura se refiere a la organización y disposición de neuronas en diferentes capas ocultas, así mismo contiene una función de activación para modificar la unidad de salida.

2.1.2.2. ENTRENAMIENTO:

Para el entrenamiento de puede utilizar diferentes algoritmos de aprendizaje entre ellos se presenta el aprendizaje supervisado y no supervisado, así mismo es necesario considerar el tipo de aprendizaje como también el algoritmo de entrenamiento como de backpropagation conocido como el algoritmo de propagación del error hacia atrás.

2.1.2.3. VALIDACIÓN Y EVALUACIÓN DE MODELOS

La medición de errores es una de las herramientas que se emplean con mayor frecuencia para determinar la exactitud de los pronósticos. Estas mediciones emplean los valores absolutos o el cuadrado de los errores. Como regla general, entre más pequeña sea la suma de los errores absolutos o de los errores cuadrados, más exacto será el ajuste del modelo.

Según Alegre (2003), menciona que una vez que ha terminado el proceso de aprendizaje y los pesos de la red neuronal han sido calculados, es importante comprobar la calidad del modelo resultante. Por ejemplo, en el caso del aprendizaje supervisado una medida de la calidad puede darse en términos de los errores entre valores de salida deseados y los valores obtenidos por la red neuronal. Algunas de las medidas estadísticas para medir la exactitud de los pronósticos son las siguientes.

a) **Error cuadrático medio (ECM):**

El error cuadrático medio mide el error global del pronóstico, el error cuadrático medio es el promedio de los cuadrados de las diferencias entre los valores pronosticados y observados.

$$\text{ECM} = \frac{1}{n} \cdot \sum_{i=1}^n (x_i - \hat{x}_i)^2$$

- ECM : Error cuadrático medio
- n : Número de observaciones
- x_i : Valor observado
- \hat{x}_i : Valor estimado por el modelo

b) Error cuadrático medio normalizado (ECMN):

$$\text{ECMN} = \frac{(n - 1)}{n} \cdot \frac{\sum_{i=1}^N (x_i - \hat{x}_i)^2}{\sum_{i=1}^N (x_i - \bar{x})^2}$$

ECMN : Error cuadrático medio normalizado

n : Número de observaciones

x_i : Valor observado

\hat{x}_i : Valor estimado por el modelo

\bar{x} : Promedio de los datos observados

c) Eficiencia de Nash y Sutcliffe (NSE):

Según Cabrera (2008), La eficiencia de Nash-Sutcliffe se utiliza para evaluar el poder predictivo de modelos hidrológicos, se puede utilizar para describir cuantitativamente la precisión de los resultados de modelos distintos de descarga. Este método puede ser usado para describir la exactitud predictiva de otros modelos siempre y cuando no se observa de datos para comparar los resultados del modelo a. Por ejemplo, la eficiencia de Nash-Sutcliffe ha sido reportada en la literatura científica para modelos de simulación de la descarga.

$$\text{NSE} = 1 - \frac{\sum_{i=1}^N (x_i - \hat{x}_i)^2}{\sum_{i=1}^N (x_i - \bar{x})^2}$$

NSE : Eficiencia de Nash y Sutcliffe

x_i : Valor observado

\hat{x}_i : Valor estimado por el modelo

\bar{x} : Promedio de los datos observados

d) Coeficiente de determinación (R^2):

Según Steel y Torrie (1960), el coeficiente de determinación, denominado R^2 es un estadístico usado en el contexto de un modelo cuyo principal propósito es predecir futuros resultados. El coeficiente determina la calidad del modelo para replicar los resultados, y la proporción de variación de los resultados que puede explicarse por el modelo. En el caso de un predictor perfecto R^2 es 1.

$$R^2 = 1 - ECMN$$

El coeficiente de determinación no solo mide la capacidad explicativa de un modelo, sino que además permite elegir entre varios modelos cual es el más adecuado. Así los modelos tienen la misma variable dependiente y el mismo número de variables explicativas, será más adecuado el que tenga un coeficiente de determinación mayor.

e) Coeficiente de correlación (r):

Según Barria (2010), Corresponde a la raíz cuadrada del coeficiente de determinación y es una medida del grado de asociación entre dos variables, si son completamente independientes el coeficiente de correlación toma valor cero.

$$r = \sqrt{R^2} = \sqrt{1 - ECMN}$$

Según Ibañez (2009), la correlación viene del latín *cum*: con y *relatus*: relacionado, la correlación lineal permite medir si hay asociación entre dos variables o medir la intensidad de dicha asociación. Los valores del coeficiente de correlación oscilan entre +1 y -1, y se explica de la siguiente manera:

- a. El valor de $r = +1$, indica una correlación positiva perfecta o correlación directa, cuando al aumentar ó disminuir el valor de la variable independiente, aumenta o disminuye también el valor de la variable dependiente (pendiente positiva).
- b. El valor de $r = -1$, expresa una correlación inversa o relación negativa perfecta: cuando al aumentar o disminuir el valor de la variable independiente, disminuye o aumenta el valor de la variable dependiente (pendiente negativa).

Los rangos que del coeficiente de correlación:

$r = 0.2$	a	$r = 0.3$	coeficiente de correlación muy bajo.
$r = 0.4$	a	$r = 0.5$	coeficiente de correlación bajo.
$r = 0.6$	a	$r = 0.7$	coeficiente de correlación alto.
$r = 0.8$	a	$r = 1.0$	coeficiente de correlación muy alto.

2.1.3. EVAPOTRANSPIRACIÓN DE REFERENCIA

Según Allen *et al* (2006) afirman que, la evapotranspiración de la superficie de referencia, denominada evapotranspiración del cultivo de referencia es la tasa de evapotranspiración de una superficie de referencia, que ocurre sin restricciones de agua, se conoce como evapotranspiración de referencia, y se denomina ET_0 .

El concepto de evapotranspiración de referencia ET_0 se introdujo para estudiar la demanda de evapotranspiración de la atmósfera en una localidad y época del año específicas, independientemente del tipo y desarrollo del cultivo, ni de los factores del suelo y de las prácticas de manejo.

Los únicos factores que afectan la ET_0 son los parámetros climáticos. Por lo tanto, la ET_0 es también un parámetro climático que puede ser calculado a partir de datos meteorológicos. Desde este punto de vista, el método FAO 56 Penman-Monteith se recomienda como el único método de determinación de la ET_0 con parámetros climáticos (Figura N° 2.15).

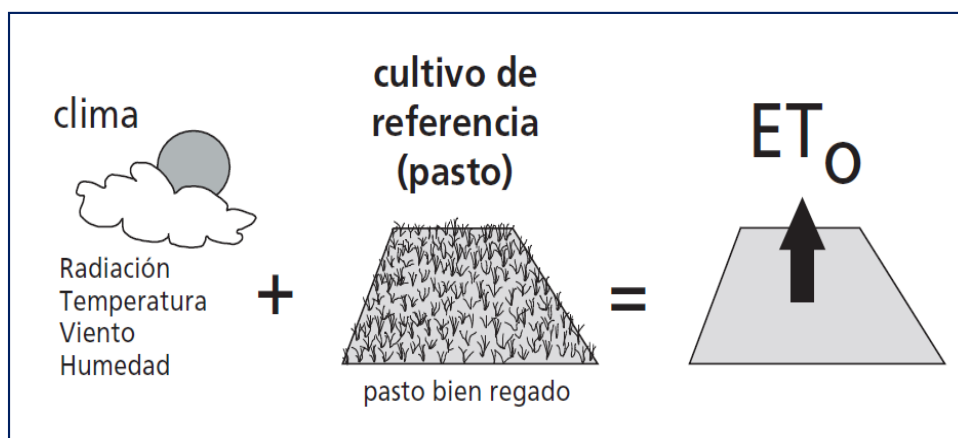


Figura N° 2.15: Evapotranspiración del cultivo de referencia.
Fuente: Allen *et al* (2006).

2.1.3.1. CULTIVO DE REFERENCIA.

Según Allen *et al* (2006) dieron a conocer que, como resultado de la consulta a expertos de la FAO realizada en mayo de 1990, para el cálculo de los requerimientos de agua de los cultivos, se presentó la siguiente definición inequívoca: “La superficie de referencia es un cultivo hipotético de pasto, con una altura asumida de 0.12 m, con una resistencia superficial fija de 70 s m^{-1} y un albedo de 0.23” (Figura N° 2.16).

El cultivo de referencia es una superficie extensa de pasto verde de altura uniforme, creciendo activamente, sombreando totalmente la tierra y bien regada con un adecuado aporte de agua. Por consiguiente, el pasto así como la alfalfa, es un cultivo muy bien estudiado con respecto a sus características aerodinámicas y superficiales y es aceptado ampliamente como superficie de referencia.




Figura N° 2.16: Características del cultivo de referencia.
Fuente: Allen et al (2006).

2.1.4. ELEMENTOS METEOROLÓGICOS QUE DETERMINAN LA (ET_o).

2.1.4.1. Temperatura.

En las estaciones meteorológicas convencionales y automáticas, la temperatura del aire se mide dentro de abrigos meteorológicos (pantallas de Stevenson o casetas ventiladas) a 2m de la superficie, de acuerdo a los estándares de la Organización Meteorológica Mundial (OMM).

La temperatura del aire se mide con termómetros o termopares instalados en el abrigo, los termómetros de mínima y máxima registran la temperatura mínima y máxima del aire en un periodo de 24 horas.

2.1.4.2. Humedad relativa.

La humedad relativa (HR) es el cociente entre la cantidad de agua que el aire realmente contiene a una determinada temperatura y la cantidad que podría contener si estuviera saturado a la misma temperatura, se expresa comúnmente como porcentaje. La variación de la humedad relativa se produce porque la presión de saturación de vapor depende de la temperatura del aire, como la temperatura del aire cambia durante el día, la humedad relativa también cambia.

2.1.4.3. Velocidad del viento.

La velocidad del viento a diversas alturas sobre la superficie del suelo tiene valores diferentes. La fricción superficial tiende a reducir la velocidad del viento que atraviesa la superficie. La velocidad del viento es menor cerca de la superficie y aumenta con la altura. Por esta razón los anemómetros se colocan en una altura estándar elegida, 10 m en meteorología y 2 ó 3 m en agrometeorología. Para el cálculo de la evapotranspiración de referencia, se requiere la velocidad del viento medida a 2 m de la superficie.

2.1.4.4. Radiación solar.

El proceso de la evapotranspiración está determinado por la cantidad de energía disponible para evaporar el agua. La radiación solar es la más importante fuente de energía en el planeta y puede cambiar grandes cantidades de agua líquida en vapor de agua.

La cantidad potencial de radiación que puede llegar a una superficie evaporante viene determinada por su localización y época del año. Debido a las diferencias en la posición del planeta y a su movimiento alrededor del sol, esta cantidad potencial de radiación es diferente para cada latitud y para las diversas estaciones del año. La radiación solar real que alcanza la superficie evaporante depende de la turbidez de la atmósfera y de la presencia de nubes que reflejan y absorben cantidades importantes de radiación. Cuando se determina el efecto de la radiación solar en la evapotranspiración, se debe también considerar que no toda la energía disponible se utiliza para evaporar el agua. Parte de la energía solar se utiliza también para calentar la atmósfera y el suelo.

2.1.5. MÉTODOS PARA ESTIMAR LA EVAPOTRANSPIRACIÓN DE REFERENCIA

2.1.5.1. MÉTODOS DIRECTOS:

a) Método del lisímetro.

Según Benites (2000), se basa en el balance de agua para la determinación de la evapotranspiración. Si el cultivo evaluado es un pasto corto con agua en el suelo a capacidad de campo, lo que se determina es la evapotranspiración potencial (ETP); si es otro cultivo a condiciones de riego normales determina la evapotranspiración real (ETr).

Según Vásquez (1984), el método de lisímetro es la forma directa y exacta de medir la evapotranspiración potencial, a partir de un aparato o estructura llamada lisímetro, durante un periodo determinado. En el interior del lisímetro, se encuentra el cultivo patrón o pasto que es materia de análisis de la cantidad de agua evaporada o transpirada.

La determinación de evapotranspiración potencial mediante un lisímetro se hace mediante la siguiente relación:

$$ETP = DA - D_d \quad (2.1)$$

Donde:

ETP = Evapotranspiración de referencia [mm/día].

DA = Cantidad de agua aplicada [mm/día].

D_d = Cantidad de agua drenada [mm/día].

b) Método del tanque de evaporación clase “A”.

Según Gurovich (1999), el método estándar de determinación de la evapotranspiración, es el evaporímetro de bandeja Standard Clase A, del U.S.W.B (Oficina de climatología de EE.UU.); este instrumento permite determinar la evaporación desde una superficie de agua, que es el mejor integrador de los factores climáticos que determinan la evapotranspiración.

Según Allen *et al* (2006), la evaporación del tanque está relacionada con la evapotranspiración de referencia por un coeficiente empírico derivado del mismo tanque; La ecuación general para estimar la evapotranspiración de referencia ETo por medio de lecturas de evaporación de una bandeja es:

$$E_{To} = K_p * E_{pan} \quad (2.2)$$

Donde:

E_{To} = Evapotranspiración de referencia [mm día⁻¹].

K_p = Coeficiente del tanque evaporímetro.

E_{pan} = Evaporación del tanque evaporímetro [mm día⁻¹].

b.1. Coeficiente del tanque:

Según Allen *et al* (1998), dependiendo del tipo de tanque y del tamaño y estado de la zona tampón (borde), los coeficientes del tanque evaporímetro tendrán valores diferentes. Cuanto más grande es la zona tampón (borde), más rápidamente el aire que se mueve sobre el tanque estará en equilibrio con ella. En equilibrio y con un gran borde, el aire contiene más vapor de agua y menos calor en el caso A que en el caso B (Figura N° 2.17).

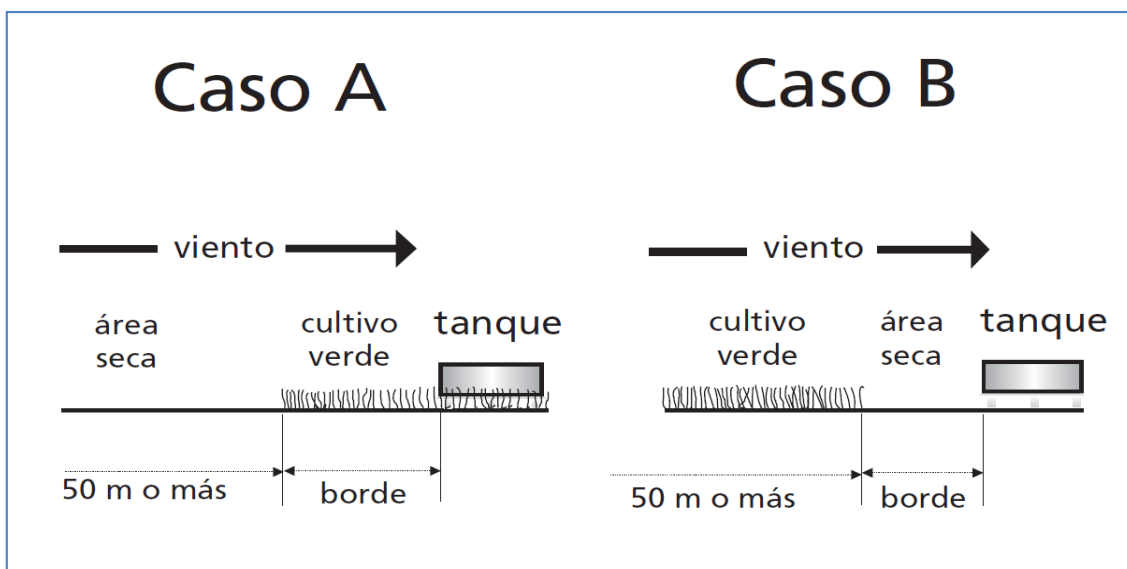


Figura N° 2.17: Casos de localización del tanque de evaporación. Fuente: Allen *et al* (2006).

Ecuación de regresión para el tanque Clase “A” situado en un cultivo verde (caso A):

$$K_p = 0.108 - 0.0286u_2 + 0.0422 \ln(\text{borde}) + 0.1434 \ln(HR_{\text{mean}}) - 0.000631 [\ln(\text{borde})]^2 \ln(HR_{\text{mean}})$$

Ecuación de regresión para el tanque Clase “A” situado en un suelo desnudo (caso B):

$$K_p = 0.61 + 0.00341 HR_{mean} - 0.000162 u_2 HR_{mean} - 0.00000959 u_2 (\text{borde}) + 0.00327 u_2 \ln(\text{borde}) - 0.00289 u_2 \ln(86.4 u_2) - 0.0106 \ln(86.4 u_2) \ln(\text{borde}) + 0.00063 [\ln(\text{borde})]^2 \ln(86.4 u_2)$$

Donde:

K_p = Coeficiente del tanque.

U_2 = Velocidad del viento diaria promedio a 2m de altura [m/s].

HR_{mean} = Humedad relativa diaria promedio [%].

borde = Distancia al borde de la superficie caso A y caso B.

Rango de variables:

$$1m \leq \text{borde} \leq 1000m$$

$$30\% \leq HR_{mean} \leq 84\%$$

$$1 \text{ m/s} \leq u_2 \leq 8\text{m/s}$$

CUADRO N° 2.4: COEFICIENTES K_p PARA EL TANQUE CLASE A

viento (Km/d)	Radio de cultivo (m)	CASO A: Tanque situado sobre pasto ó cultivo			Radio de suelo desnudo (m)	CASO B: Tanque situado sobre suelo desnudo			
		Humedad Relativa media (%)				Humedad Relativa media (%)			
		Baja	Media	Alta		Baja	Media	Alta	
		< 40	40 -70	> 70			< 40	40 -70	> 70
Ligero < 175 Km/d (<2 m/s)	1	0.55	0.65	0.75	1	0.70	0.80	0.85	
	10	0.65	0.75	0.85	10	0.60	0.70	0.80	
	100	0.70	0.80	0.85	100	0.55	0.65	0.75	
	1000	0.75	0.85	0.85	1000	0.50	0.60	0.70	
Moderado 175-425 Km/d (2-5 m/s)	1	0.50	0.60	0.65	1	0.65	0.75	0.80	
	10	0.60	0.70	0.75	10	0.55	0.65	0.70	
	100	0.65	0.75	0.80	100	0.50	0.60	0.65	
	1000	0.70	0.80	0.80	1000	0.45	0.55	0.60	
Fuerte 425-700 Km/d (5-8 m/s)	1	0.45	0.50	0.60	1	0.60	0.65	0.70	
	10	0.55	0.60	0.65	10	0.50	0.55	0.65	
	100	0.60	0.65	0.70	100	0.45	0.50	0.60	
	1000	0.65	0.70	0.75	1000	0.40	0.45	0.55	
Muy fuerte > 700 Km/d (>8 m/s)	1	0.40	0.45	0.50	1	0.50	0.60	0.65	
	10	0.45	0.55	0.60	10	0.45	0.50	0.55	
	100	0.50	0.60	0.65	100	0.40	0.45	0.50	
	1000	0.55	0.60	0.65	1000	0.35	0.40	0.45	

Fuente: Allen et al (2006).

2.1.5.2. MÉTODOS INDIRECTOS:

a) Método de FAO 56 Penman - Monteith.

Según Allen *et al* (2006), en mayo de 1990 la FAO organizó un panel de expertos con el fin de revisar las metodologías previamente propuestas por la FAO para el cálculo de los requerimientos de agua de los cultivos y para elaborar recomendaciones y actualizar procedimientos, respecto a este.

El método de FAO 56 Penman-Monteith fue seleccionado y recomendado como el único método estándar para determinar la evapotranspiración de referencia (ET_o), dado que ha demostrado un mejor comportamiento y consistencia al determinar la ET_o en el ámbito global, en una amplia gama geográfica y climática. Así mismo, este método reduce las imprecisiones del método FAO Penman; por consiguiente no aconseja el uso de ecuaciones antiguas de la FAO o de otras ecuaciones para el cálculo de la ET_o.

a.1. Ecuación de FAO 56 Penman-Monteith

La ecuación de FAO 56 Penman -Monteith para estimar la evapotranspiración de referencia (ET_o) fue derivado de la ecuación original de Penman - Monteith y de las ecuaciones de resistencia aerodinámica y la resistencia superficial.

Para el cálculo de la ecuación del método de FAO 56 Penman - Monteith se requiere datos de radiación solar, temperatura del aire, humedad relativa y velocidad del viento, la ecuación (2.3) determina la ET_o.

La ecuación utilizada por la FAO 56 Penman –Monteith para periodos diarios es:

$$E_{To} = \frac{0.408 \Delta (R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34 u_2)} \quad (2.3)$$

Donde:

- E_{To} = Evapotranspiración de referencia [mm día^{-1}]
- R_n = Radiación neta en la superficie del cultivo [$\text{MJ m}^{-2} \text{ día}^{-1}$]
- R_a = Radiación extraterrestre [mm día^{-1}]
- G = Flujo del calor de suelo [$\text{MJ m}^{-2} \text{ día}^{-1}$]
- T = Temperatura media del aire a 2 m de altura [$^{\circ}\text{C}$]
- U_2 = Velocidad del viento a 2 m de altura [m s^{-1}]
- e_s = Presión de vapor de saturación [kPa]
- e_a = Presión real de vapor [kPa]
- $e_s - e_a$ = Déficit de presión de vapor [kPa]
- Δ = Pendiente de la curva de presión de vapor [$\text{kPa } ^{\circ}\text{C}^{-1}$]
- γ = Constante psicrométrica [$\text{kPa } ^{\circ}\text{C}^{-1}$]

a.2. Parámetros de la Ecuación de FAO 56 Penman – Monteith.

1. PARÁMETROS DE RADIACIÓN:

a. Radiación neta en la superficie del cultivo (R_n).

La radiación neta R_n es la diferencia entre la radiación entrante y saliente de longitudes de onda cortas y largas. Expresado de otra manera es el equilibrio entre la energía absorbida, reflejada y emitida por la superficie terrestre o la diferencia de la radiación de onda corta entrante (R_{ns}) y la radiación de onda larga saliente (R_{nl}) (Figura N° 2.18). La R_n es normalmente positiva en el día y negativa en la noche.




Figura N° 2.18: Componentes de la radiación.
Fuente: Allen et al (2006).

La radiación neta (R_n) es la diferencia entre la radiación neta de onda corta (R_{ns}) y la radiación neta de onda larga (R_{nl}).

$$R_n = R_{ns} - R_{nl} \quad (2.4)$$

Donde:

R_n = Radiación neta [$\text{MJ m}^{-2} \text{ dia}^{-1}$].

R_{ns} = Radiación neta de onda corta [$\text{MJ m}^{-2} \text{ dia}^{-1}$].

R_{nl} = Radiación neta de onda larga [$\text{MJ m}^{-2} \text{ dia}^{-1}$].

b. Radiación neta de onda corta (R_{ns}).

Una cantidad considerable de la radiación solar que llega a la superficie de la tierra se refleja. La fracción α , de la radiación solar que es reflejada por la superficie se conoce como albedo. El albedo es muy variable de acuerdo al tipo de superficie y el ángulo de incidencia o la pendiente de la superficie terrestre.

Este parámetro varía desde 0.95 para la nieve recientemente caída a 0.05 para un suelo desnudo y húmedo. Una cubierta verde de vegetación tiene un albedo de entre 0.20 a 0.25, para el cultivo de referencia, se asume que α tiene un valor de 0.23 (Figura N° 2.18).

La radiación neta de onda corta resultante del equilibrio entre la radiación solar entrante y la reflejada está dada por:

$$R_{ns} = [1 - \alpha]R_s \quad (2.5)$$

Donde:

R_{ns} = radiación neta de onda corta [$\text{MJ m}^{-2} \text{ dia}^{-1}$].

α = α albedo ó coeficiente de reflexión del cultivo, para cultivo de referencia es 0.23.

R_s = radiación solar entrante [$\text{MJ m}^{-2} \text{ dia}^{-1}$].

c. Radiación neta de onda larga (R_{nl}).

La radiación solar absorbida por la tierra se convierte en energía térmica. Por varios procesos, incluyendo la emisión de radiación, la tierra pierde esta energía. La tierra, que tiene una temperatura mucho más baja que el sol, emite energía radiante con longitudes de onda más largas que el sol. Por ello, la radiación terrestre se conoce como radiación de onda larga.

La radiación de onda larga emitida por el planeta es absorbida por la atmosfera, así la atmosfera irradia también energía que se dirige a la tierra. Por lo tanto, la superficie terrestre emite y recibe radiación de onda larga. La diferencia entre la radiación de onda larga entrante y saliente se llama radiación neta de onda larga, R_{nl} (Figura N° 2.18).

La ley de Stefan-Boltzmann utiliza el promedio de la temperatura mínima y máxima elevada a la cuarta potencia. El termino $(0,34-0,14\sqrt{e_a})$ expresa la corrección para la humedad del aire, y será más pequeño con valores más elevados de humedad. El efecto de la nubosidad se expresa por $(1,35 R_s/R_{so} - 0,35)$.

$$R_{nl} = \sigma \left[\frac{T_{\max,K}^4 + T_{\min,K}^4}{2} \right] * [0,34 - 0,14\sqrt{e_a}] * \left[1,35 \frac{R_s}{R_{so}} - 0,35 \right] \quad (2.6)$$

Donde:

- R_{nl} = Radiación neta de onda larga [$\text{MJ m}^{-2} \text{ día}^{-1}$].
 σ = Constante de Stefan-Boltzmann [$4.903 \times 10^{-9} \text{ MJ K}^{-4} \text{ m}^{-2} \text{ día}^{-1}$].
 $T_{\text{max},K}$ = Temperatura máxima absoluta en un periodo de 24 horas [$K = ^\circ\text{C} + 273.16$].
 $T_{\text{min},K}$ = Temperatura mínima absoluta en un periodo de 24 horas [$K = ^\circ\text{C} + 273.16$].
 e_a = Presión de vapor real [kPa].
 R_s/R_{s0} = Radiación relativa de onda corta (valores ≤ 1.0).
 R_s = Radiación solar medida o calculada (Ecuación 2.7) [$\text{MJ m}^{-2} \text{ día}^{-1}$].
 R_{s0} = Radiación en un día despejado (Ecuación 2.9 o 2.10) [$\text{MJ m}^{-2} \text{ día}^{-1}$].

d. Radiación solar (R_s).

La radiación solar R_s es una fracción de la radiación extraterrestre R_a ; cuando la radiación extraterrestre atraviesa la atmosfera para llegar a la superficie terrestre, parte de ella se refleja y se absorbe al atravesar la atmósfera. La cantidad de radiación que llega a un plano horizontal en la superficie terrestre se conoce como radiación solar, R_s (Figura N° 2.16). En un día despejado, R_s constituye aproximadamente el 75% de la radiación extraterrestre y en un día nublado este valor disminuye a 25% de la radiación extraterrestre.

$$R_s = \left[a_s + b_s \frac{n}{N} \right] R_a \quad (2.7)$$

Donde:

- R_s = Radiación solar o de onda corta [$\text{MJ m}^{-2} \text{ día}^{-1}$].
 n = Duración real de la insolación [horas]
 N = Duración máxima posible de la insolación [horas]
 n/N = Duración relativa de la insolación[-]
 R_a = Radiación extraterrestre [$\text{MJ m}^{-2} \text{ día}^{-1}$]
 a_s = constante de regresión, que expresa la fracción radiación
 $a_s + b_s$ = Fracción de la radiación extraterrestre que llega a la tierra en días despejados

e. Duración máxima de la insolación (N).

La duración máxima de la insolación N, está dada por la (ecuación 2.8). Los valores medios para N (día 15 de cada mes) para diferentes latitudes se presentan en el Anexo N° 2.1.

$$N = \frac{24}{\pi} * \omega_s \quad (2.8)$$

Donde:

N = Duración máxima de la insolación [horas]

ω_s = Ángulo de radiación a la puesta del sol (Ecuación 2.13) [rad].

f. Radiación solar en un día despejado (R_{s0}).

R_s es la radiación solar que realmente llega a la superficie terrestre en un determinado periodo, mientras que R_{s0} es la radiación solar que alcanzaría la misma superficie durante el mismo periodo si el cielo estuviera despejado. Para el cálculo de la radiación solar en días despejados R_{s0} , cuando $n=N$, puede ser calculada de la siguiente manera.

En casos en que los valores calibrados de a_s y b_s estén disponibles:

$$R_{s0} = [a_s + b_s] R_a \quad (2.9)$$

Donde:

R_{s0} = Radiación solar en un día despejado [$\text{MJ m}^{-2} \text{ dia}^{-1}$].

$a_s + b_s$ = Fracción de la radiación extraterrestre que llega a la tierra en días despejados.

En casos en que los valores calibrados de a_s y b_s no estén disponibles:

$$R_{s0} = [0.75 + 2 * 10^{-5} * Z] R_a \quad (2.10)$$

Donde:

R_{s0} = Radiación solar en un día despejado [$\text{MJ m}^{-2} \text{ dia}^{-1}$].

Z = Elevación de la estación sobre el nivel de mar [m].

g. Radiación extraterrestre (R_a).

La radiación solar recibida en la parte superior de la atmosfera terrestre sobre una superficie horizontal se conoce como radiación (solar) extraterrestre R_a . Si el sol se encuentra directamente encima de la cabeza, el ángulo de incidencia es cero y la radiación extraterrestre es $0,082 \text{ MJ m}^{-2} \text{ min}^{-1}$. Así como las estaciones cambian, la posición del sol, la radiación extraterrestre también cambia. De esta forma La radiación extraterrestre es una función de la latitud, la época del año y la hora del día.

La radiación extraterrestre R_a , para cada día y para diversas latitudes se puede estimar a partir de la constante solar, la declinación solar y época del año.

$$R_a = \frac{24 * 60}{\pi} * G_{SC} * d_r [\omega_s \sin(\varphi) \sin(\delta) + \cos(\varphi) \cos(\delta) \sin(\omega_s)] \quad (2.11)$$

Donde:

- R_a = Radiación extraterrestre [$\text{MJ m}^{-2} \text{ dia}^{-1}$].
- G_{SC} = constante solar = $0,082 \text{ MJ m}^{-2} \text{ min}^{-1}$
- d_r = distancia relativa inversa Tierra-Sol (Ecuación 2.29)
- ω_s = ángulo de radiación a la puesta del sol (Ecuaciones 2.13 o 2.28) [rad]
- φ = latitud [rad] (Ecuación 2.14)
- δ = Declinación solar (Ecuación 2.15) [rad]

Distancia relativa inversa Tierra-Sol (d_r).

Para calcular la distancia relativa inversa Tierra-Sol (d_r), es necesario seleccionar J , donde J es el número del día en el año entre 1 (1 de enero) y 365 (31 de diciembre); los valores de J para todos los días del año y una ecuación para estimar su valor se presentan en el Anexo N° 2.2.

$$d_r = 1 + 0.033 * \cos\left(\frac{2\pi}{365} \cdot J\right) \quad (2.12)$$

Ángulo de radiación (ω_s).

Ángulo de radiación (ω_s), a la hora de la puesta del sol se da por:

$$\omega_s = \arcsin[-\tan(\varphi) * \tan(\delta)] \quad (2.13)$$

Latitud φ [rad].

La latitud (φ), expresada en radianes es positiva para el hemisferio norte y negativa para el hemisferio sur. La conversión de grados decimales a radianes se da por:

$$\varphi[\text{rad}] = \frac{\pi}{180} [\text{latitud en grados decimales}] \quad (2.14)$$

Declinación solar (δ).

Para calcular la declinación solar (δ), es necesario seleccionar J, donde J es el número del día en el año entre 1 (1 de enero) y 365 (31 de diciembre); los valores de J para todos los días del año se presentan en el Anexo N° 2.2.

$$\delta = 0.409 * \sin\left(\frac{2\pi}{365} J - 1.39\right) \quad (2.15)$$

h. Flujo del calor de suelo (G).

El flujo del calor del suelo G, es la energía que se utiliza para calentar el suelo. G tiene valores positivos cuando el suelo se calienta y negativos cuando el suelo se enfría. Aunque el flujo calórico del suelo es pequeño comparado con R_n y puede ser no considerado con frecuencia, la cantidad de energía ganada o perdida por el suelo en este proceso teóricamente debe restarse o agregarse a R_n para estimar la evapotranspiración, por lo tanto se puede calcular el flujo del calor del suelo para periodos cortos y largos.

Para periodos diarios: Como la magnitud del flujo de calor bajo la superficie de referencia es relativamente pequeña, esta puede ser ignorada y entonces:

$$G_{\text{día}} = 0 \quad (2.16)$$

Para periodos mensuales: Si se asume una capacidad calorífica constante del suelo de $2.1 \text{ MJ m}^{-3} \text{ }^{\circ}\text{C}^{-1}$ y una profundidad media de suelo.

$$G_{\text{mes}} = 0.07 (T_{\text{mes},i+1} - T_{\text{mes},i-1}) \quad (2.17)$$

Donde:

$T_{\text{mes}, i}$ = temperatura media del aire en el mes i [$^{\circ}\text{C}$]

$T_{\text{mes}, i-1}$ = temperatura media del aire en el mes $i-1$ [$^{\circ}\text{C}$]

$T_{\text{mes}, i+1}$ = temperatura media del aire en el mes $i+1$ [$^{\circ}\text{C}$]

2. CONVERSIÓN DE VELOCIDAD DEL VIENTO

a. Velocidad del viento a 2 m de altura (u_2).

La velocidad del viento a diversas alturas sobre la superficie del suelo tiene diferentes valores. La fricción superficial tiende a reducir la velocidad del viento que atraviesa la superficie. La velocidad del viento es menor cerca de la superficie y aumenta con altura.

Por esta razón los anemómetros se colocan a una altura estándar elegida, 10 m en meteorología y 2 ó 3 m en agrometeorología. Para el cálculo de la evapotranspiración, se requiere la velocidad del viento medida a 2 m sobre la superficie. Para ajustar los datos de velocidad del viento obtenido de instrumentos situados a elevaciones diferentes a la altura estándar de 2 m, se puede usar una relación logarítmica, los valores se presentan en el Anexo N° 2.3.

$$u_2 = u_z * \frac{4.87}{\ln(67.8 * z - 5.42)} \quad (2.18)$$

Donde:

u_2 = velocidad del viento a 2m de altura [m s^{-1}].

u_z = velocidad del viento medida a z m sobre la superficie [m s^{-1}].

z = altura de medición sobre la superficie [m].

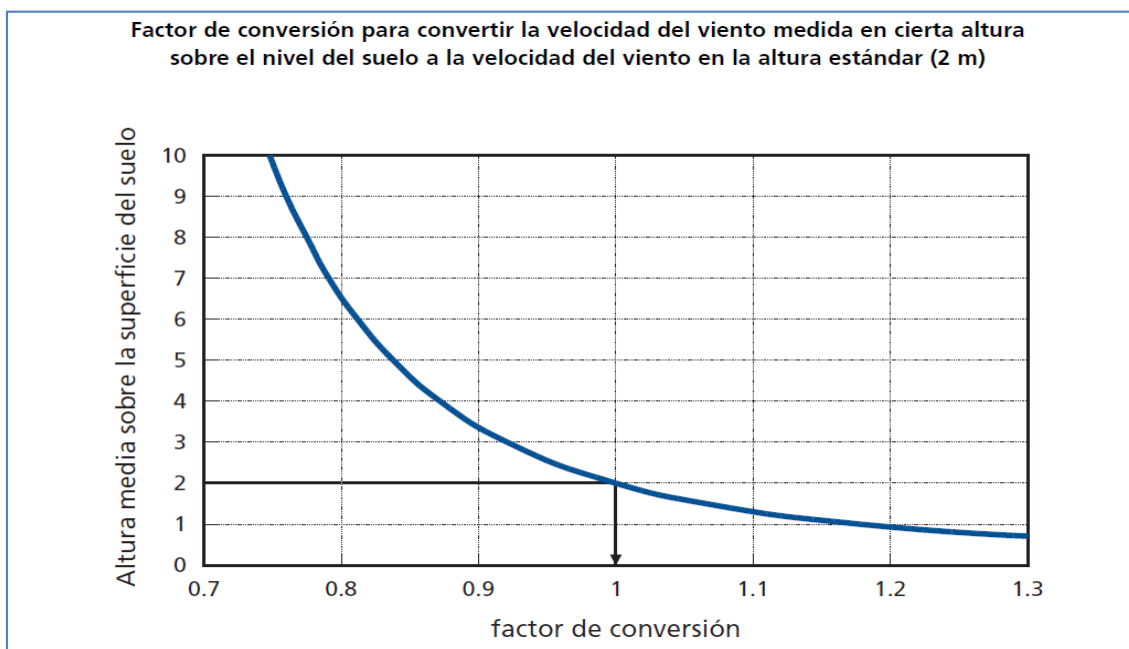


Figura N° 2.19: Factores de conversión para convertir la velocidad del viento. Fuente: Allen et al (2006).

3. PARÁMETROS DE HUMEDAD

a. Presión de vapor de saturación (e_s).

La presión de saturación de vapor puede ser calculada en función de la temperatura del aire, pues depende de ella. La relación entre ambas variables se expresa como:

$$e^o(T) = 0.6108 * \exp \left[\frac{17.27 * T}{T + 237.3} \right] \quad (2.19)$$

Donde:

$e^o(T)$ = presión de saturación de vapor a la temperatura del aire, T [kPa]

T = temperatura del aire [°C]

exp = 2.7183 (base del logaritmo natural) elevado a la potencia [...]

El uso de la temperatura media del aire en lugar de T_{max} y T_{min} da lugar a subestimaciones de la presión media de saturación de vapor, lo cual llevaría a una subestimación de la ETo . Por lo tanto, es recomendable calcular la presión de

saturación de vapor como el promedio de la presión de saturación de vapor a la temperatura máxima y a la temperatura mínima del aire.

$$e_s = \frac{e^{\circ}(T_{\max}) + e^{\circ}(T_{\min})}{2} \quad (2.20)$$

Donde:

e_s = presión de saturación de vapor [kPa]

$e^{\circ}(T_{\min})$ = presión de saturación de vapor a la temperatura mínima diaria [kPa]

$e^{\circ}(T_{\max})$ = presión de saturación de vapor a la temperatura máxima diaria [kPa]

Los valores de la presión de saturación de vapor en función de la temperatura del aire se presentan en el Anexo N° 2.4.

b. Presión real de vapor (e_a).

La presión real de vapor se puede también derivar de la humedad relativa, dependiendo de la disponibilidad de datos de humedad, se pueden utilizar diversas ecuaciones.

$$e_a = \frac{e^{\circ}(T_{\min}) \frac{HR_{\max}}{100} + e^{\circ}(T_{\max}) \frac{HR_{\min}}{100}}{2} \quad (2.21)$$

Donde

e_a = presión real de vapor [kPa]

$e^{\circ}(T_{\min})$ = presión de saturación de vapor a la temperatura mínima diaria [kPa]

$e^{\circ}(T_{\max})$ = presión de saturación de vapor a la temperatura máxima diaria [kPa]

HR_{\max} = humedad relativa máxima [%]

HR_{\min} = humedad relativa mínima [%]

c. Déficit de presión de vapor ($e_s - e_a$):

El déficit de presión de vapor es la diferencia entre la presión de saturación de vapor (e_s) y la presión real de vapor (e_a) durante un determinado periodo.

$$(e_s - e_a) = \left[\frac{e^o(T_{\max}) + e^o(T_{\min})}{2} \right] - \left[\frac{e^o(T_{\min}) \frac{HR_{\max}}{100} + e^o(T_{\max}) \frac{HR_{\min}}{100}}{2} \right] \quad (2.22)$$

d. Pendiente de la curva de presión de vapor (Δ):

Para el cálculo de evapotranspiración, se requiere calcular la pendiente de la relación entre la presión de saturación de vapor y la temperatura. La pendiente de la curva a una temperatura dada se da por:

$$\Delta = \frac{4098 * \left[0.6108 * \exp \left(\frac{17.27 * T}{T + 237.3} \right) \right]}{(T + 237.3)^2} \quad (2.23)$$

Donde:

Δ = pendiente de la curva de la presión de saturación de vapor [kPa °C⁻¹]

T = temperatura media del aire [°C]

exp = 2.7183 (base del logaritmo natural) elevado a la potencia [..]

Los valores de la pendiente (Δ) para diversas temperaturas del aire se presentan en el Anexo N° 2.5. Para su aplicación en la ecuación FAO 56 Penman - Monteith, la pendiente de la curva de presión de vapor (Δ) se calcula usando la temperatura media.

4. PARÁMETROS ATMOSFÉRICOS:

a. Constante psicrométrica (γ):

El calor específico es la cantidad de energía requerida para aumentar la temperatura de una unidad de masa de aire en 1°C a presión constante. Su valor depende de la composición del aire, fundamentalmente de su humedad. Para condiciones atmosféricas medias se puede utilizar el $C_p = 1.013 \times 10^{-3} \text{ MJ kg}^{-1} \text{ }^\circ\text{C}^{-1}$.

1. Dado que se aplica un valor medio de presión atmosférica en cada localidad (Ecuación 2.24), la constante psicrométrica también se mantiene constante para cada localidad. Los valores para la constante psicrométrica en función de la altitud se encuentran en el Anexo N° 2.6.

$$\gamma = \frac{C_p * P}{\varepsilon * \lambda} = 0.665 * 10^{-3} * P \quad (2.24)$$

Donde:

γ = constante psicrométrica [kPa $^\circ\text{C}^{-1}$]

P = presión atmosférica [kPa]

λ = calor latente de vaporización, 2.45 [MJ kg $^{-1}$]

C_p = calor específico a presión constante, 1.013×10^{-3} [MJ kg $^{-1} \text{ }^\circ\text{C}^{-1}$]

ε = cociente del peso molecular de vapor de agua /aire seco = 0.622.

b. Calor latente de vaporización (λ):

El calor latente de vaporización λ , expresa la energía requerida para cambiar una masa de unidad de agua líquida a vapor de agua bajo presión y temperatura constantes. El valor del calor latente de vaporización varía en función de la temperatura. Cuanto más elevada sea la temperatura, menos energía será requerida. Como λ varía levemente dentro de rangos de temperaturas normales, se considera un valor constante de 2,45 MJ kg $^{-1}$ para la simplificación de la ecuación de FAO Penman-Monteith. Este valor corresponde al calor latente de vaporización a una temperatura del aire de alrededor de 20 °C.

c. Presión atmosférica (P).

La presión atmosférica es la presión ejercida por el peso de la atmosfera terrestre, La evaporación en altitudes elevadas ocurre en parte gracias a la baja presión atmosférica que se expresa con la constante psicrométrica. Este efecto es, sin embargo, pequeño y en los procedimientos del cálculo, el valor medio para una localidad es suficiente. Para calcular P puede emplearse una simplificación de la ley de los gases ideales, a una temperatura atmosférica estándar de 20°C.

$$P = 101.3 \left[\frac{293 - 0.0065 * Z}{293} \right]^{5.26} \quad (2.25)$$

Donde:

P = presión atmosférica [kPa]

Z = elevación sobre el nivel del mar [m]

b) Método de Hargreaves - Samani (1985)

Según Allen *et al* (2006), cuando no se tiene disponibilidad de datos meteorológicos de radiación solar, humedad relativa y velocidad del viento; la evapotranspiración de referencia ETo puede ser estimada utilizando la ecuación de Hargreaves (1985).

$$ETo = 0.0023 (T_{media} + 17.8)(T_{max} - T_{min})^{0.5} R_a \quad (2.26)$$

Donde:

ETo = Evapotranspiración de referencia [mm día⁻¹].

T_{media} = Temperatura media [°C].

T_{max} = Temperatura máxima [°C].

T_{min} = Temperatura mínima [°C].

R_a = Radiación solar extraterrestre (Ecuación 2.11 o 2.27) [mm día⁻¹].

La ecuación (2.27) explica la radiación extraterrestre. Por lo tanto también es necesario utilizar las ecuaciones (2.13), (2.12) y (2.15).

$$R_a = \frac{24 * 60}{\pi} * 0.082 * d_r [\omega_s \sin(\varphi) \sin(\delta) + \cos(\varphi) \cos(\delta) \sin(\omega_s)] \quad (2.27)$$

2.2. MARCO CONCEPTUAL:

2.2.1. Modelo.

Según Caracheo (2002), considera al modelo, en términos generales, como representación de la realidad, explicación de un fenómeno, ideal digno de imitarse, paradigma, canon, patrón o guía acción; idealizada de la realidad, arquetipo, prototipo, uno entre una serie de objetos similares, un conjunto de elementos esenciales o los supuestos teóricos de un sistema social.

2.2.2. Redes Neuronales Artificiales.

Según Hilera y Martínez (1995), indica que las redes neuronales artificiales son redes interconectadas masivamente en paralelo de elementos simples y con organización jerárquica, las cuales intentan interactuar con los objetivos del mundo real del mismo modo que lo hace el sistema nervioso biológico.

Según Flórez y Fernández (2008), una red neuronal artificial (RNA) puede considerarse un modelo matemático de las teóricas actividades mentales y cerebrales, basados en la explotación del procesamiento local en paralelo y las propiedades de la representación distribuida.

2.2.3. Evaporación.

Según Vásquez (1984), es el proceso físico, mediante el cual, el agua cambia del estado líquido a vapor. La evaporación constituye una de las fases del ciclo hidrológico, y está influenciada por diversos factores entre los cuales se tienen viento, temperatura, humedad relativa, radiación, composición y color del suelo. En el caso de los cultivos, cuando hablamos de evaporación, nos estamos refiriendo a la evaporación del agua que se encuentra en el suelo.

2.2.4. Transpiración.

Según Vásquez (1984), es el fenómeno por el cual el agua en estado de vapor se mueve desde el mesófilo de la planta hacia la atmosfera. Es decir, el flujo de agua de la planta a la atmosfera ocurre a través de los estomas y de las otras células epidérmicas, a través de la cutícula de la planta.

2.2.5. Evapotranspiración.

Según Tarjuelo (1999), el concepto de evapotranspiración obedece a que, en un terreno ocupado por un cultivo, el agua pasa a la atmosfera en dos formas diferentes; por evaporación directa desde el suelo y por transpiración o evaporación desde los estomas de las plantas del agua que éstas han absorbido del suelo.

2.2.6. Evapotranspiración potencial (ETP).

Según Thornthwaite (1948), definió a la evapotranspiración potencial (ETP) como la máxima cantidad de agua que puede evaporarse desde un suelo completamente cubierto de vegetación, que se desarrolla en óptimas condiciones, y sin limitaciones en la disponibilidad de agua. Según esta definición, la magnitud de la ETP está regulada solamente por condiciones meteorológicas o climáticas, según el caso, del momento o período para el cual se realiza la estimación.

2.2.7. Evapotranspiración de referencia (ETo).

Según Doorenbos y Pruitt (1975), definió a la evapotranspiración de referencia (ETo) como la tasa de evaporación de una superficie extensa de gramíneas verdes de 8 a 15 centímetros de altura, uniforme, de crecimiento activo, que sombrea totalmente el suelo y que no escasean de agua.

2.2.8. Evapotranspiración real (ETr).

Según Benites (2000), se refiere a la cantidad real de vapor transferida a la atmósfera, que depende no solo de las condiciones meteorológicas existentes, sino del ciclo vegetativo del cultivo (capacidad para extraer humedad) y de las disponibilidades de agua reales por efecto de la periodicidad con que se aplica el agua.

2.2.9. Factor de cultivo (Kc).

Según Vásquez (1984), llamado también coeficiente de cultivo, es un factor que indica el grado de desarrollo o cobertura del suelo por el cultivo del cual se requiere evaluar su consumo de agua; el Kc depende de las características anatómicas, morfológicas y fisiológicas de los cultivos, y expresa la variación de su capacidad para extraer agua del suelo durante su ciclo vegetativo.

2.2.10. Necesidades de agua de riego.

Según Benites (2000), se ha determinado que el uso de agua de los cultivos, vendría a ser la cantidad de agua requerida para su normal desarrollo, que depende de varios factores entre ellos clima, ciclo vegetativo, tipo de cultivo. El cálculo de dicha necesidad se puede establecer por medio de la Evapotranspiración Potencial (ETP) afectada por el coeficiente del cultivo Kc, que vendría a ser la Evapotranspiración Real (ETr).

Según Doorenbos y Pruitt (1975), las necesidades de riego se refieren a la cantidad de agua y al momento de su aplicación con el objeto de compensar el déficit de humedad del suelo durante el periodo vegetativo de un cultivo.

CAPITULO III

MATERIALES Y MÉTODOS

3.1. DESCRIPCIÓN DEL AMBITO DE ESTUDIO:

3.1.1. UBICACIÓN DEL AMBITO DE ESTUDIO:

3.1.1.1. Ubicación Geográfica:

La cuenca del rio Huancané tiene la siguiente ubicación geográfica:

Coordenadas Geográficas:

Latitud Sur : 14° 31' 26" - 15° 23' 07"

Longitud Oeste: 70° 07' 06" - 69° 29' 12"

Coordenadas UTM (WGS84):

Este : 376 030 – 468 557

Norte : 8 301 965 – 8 397 410

Altitud entre : 3806 – 5100 msnm.

3.1.1.2. Ubicación Hidrográfica:

Hidrográficamente la cuenca del rio Huancané se encuentra ubicada en:

Región hidrográfica : Titicaca

Sistema hídrico : TDPS

3.1.1.3. Ubicación Política:

La cuenca del rio Huancané tiene la siguiente ubicación política:

Región : Puno

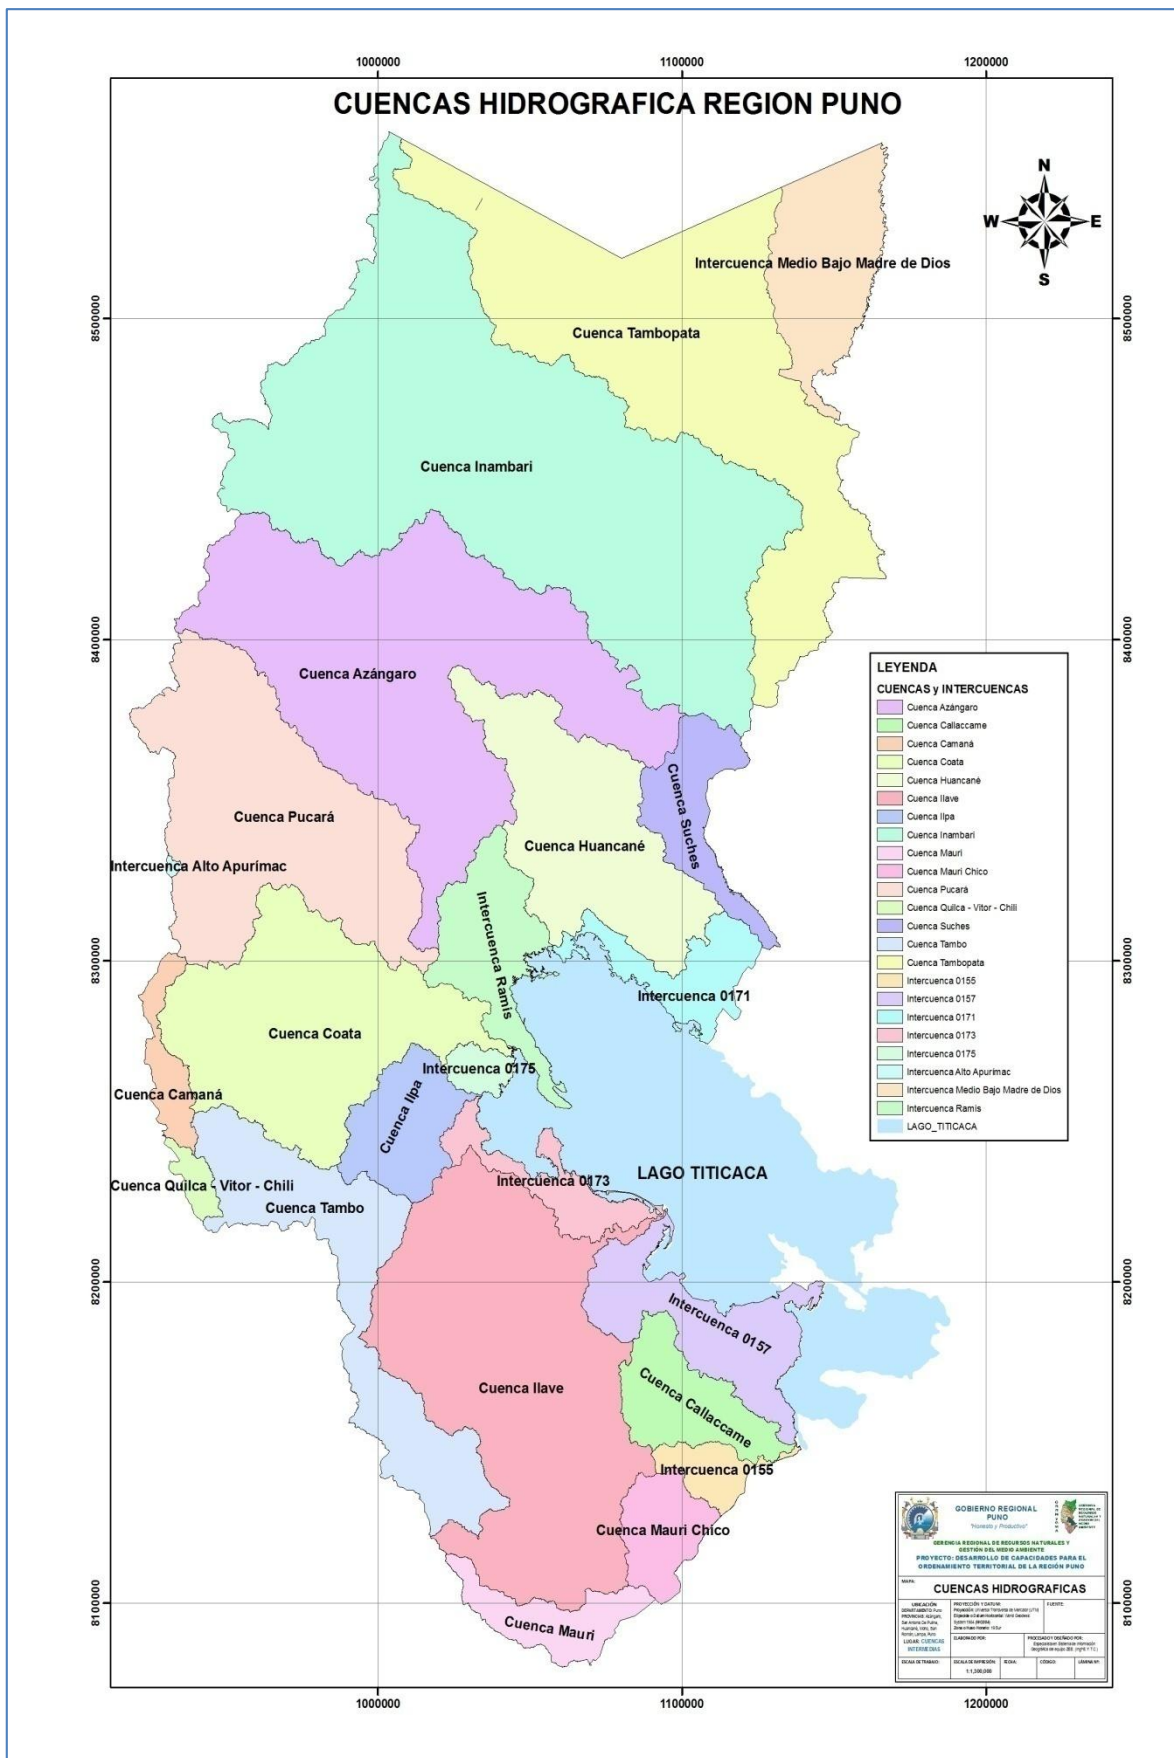
Provincias: Huancané, San Antonio de Putina, Moho y Azángaro.

Distritos : Huancané, Vilquechico, Huayrapata, Rosaspata, Cojata, Potoni,
Inchupalla, Huatasani, Quilcapunco, Putina, Muñani, Ananea

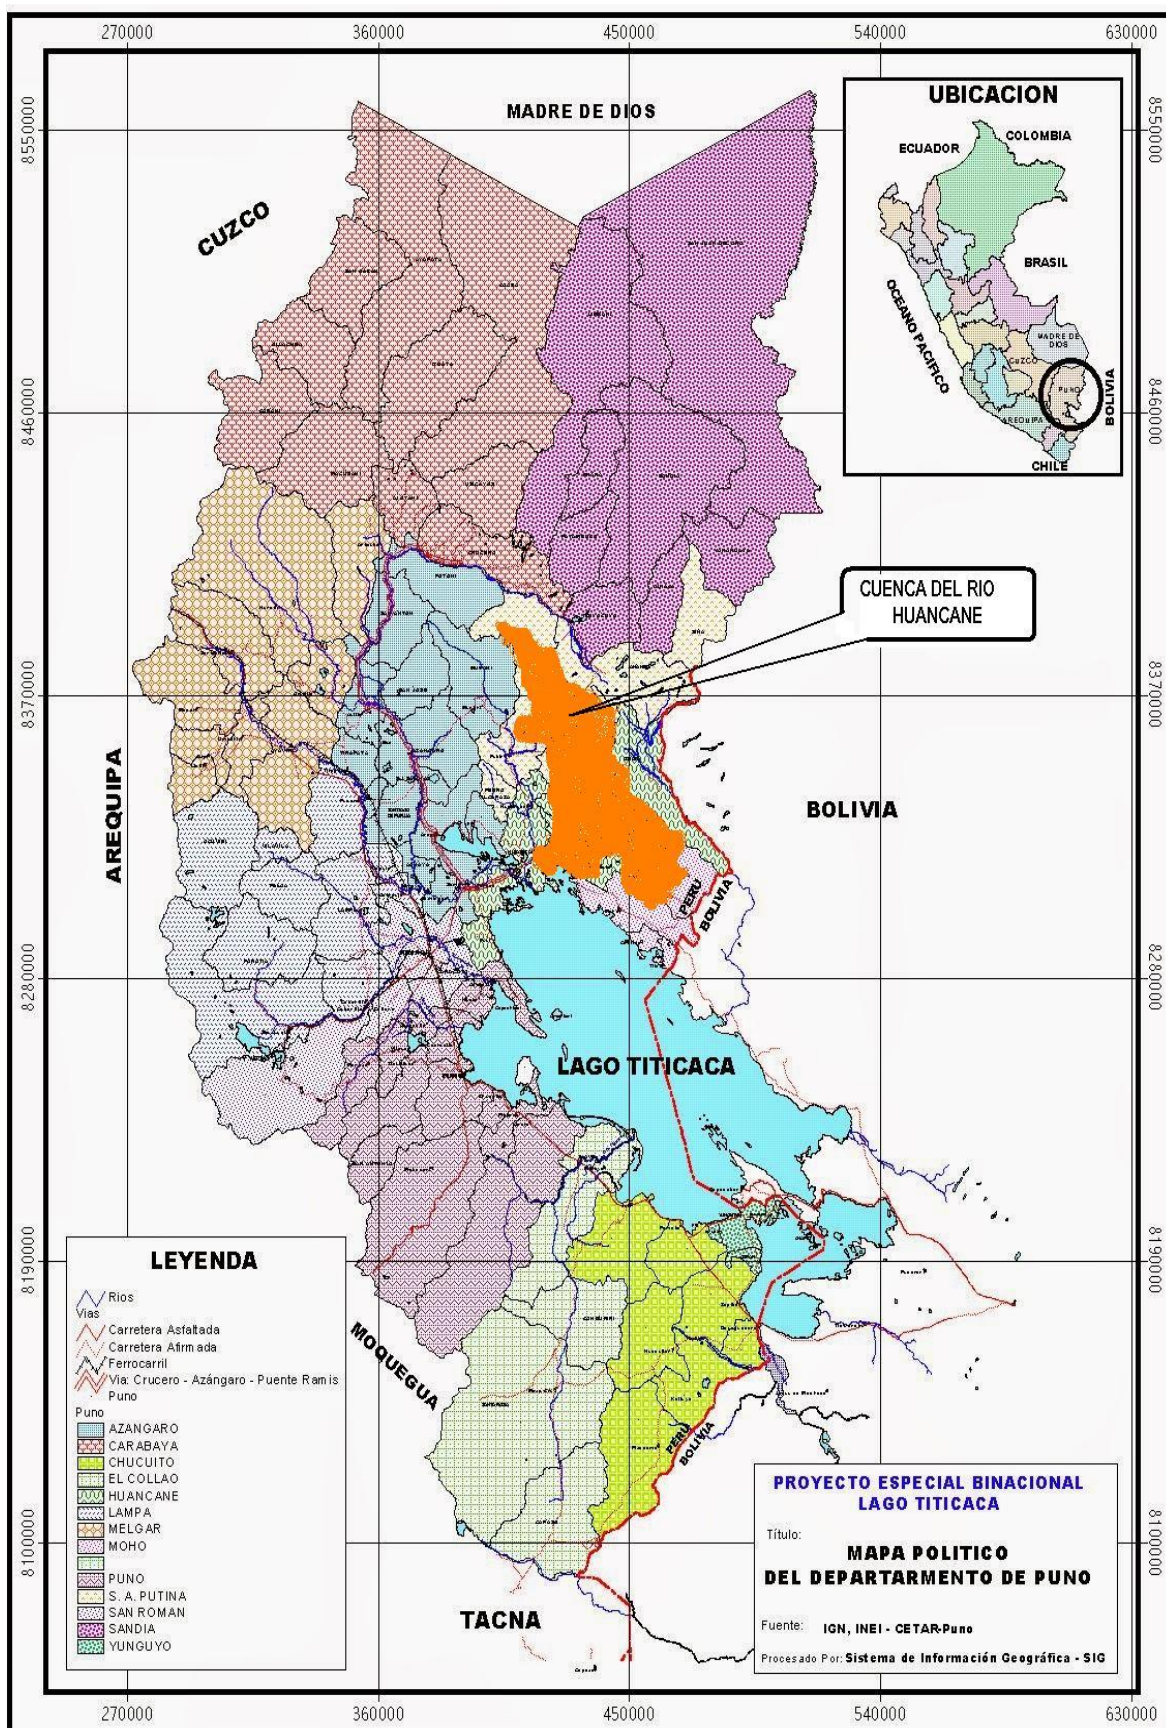
Mapa N° 3.1: Ubicación Geográfica de la cuenca del Río Huancané.



Mapa N° 3.2: Ubicación Hidrográfica de la cuenca del río Huancañé.



Mapa N° 3.3: Ubicación Política de la cuenca del Río Huancané.



3.1.1.4. Ubicación administrativa:

La cuenca del río Huancané se enmarca dentro del ámbito jurisdiccional de la Administración Local del Agua Huancané, cuya dependencia técnica, funcional y administrativa es de la Autoridad Nacional del Agua (ANA) con sede en la ciudad de Lima. La sede administrativa se encuentra ubicado en la ciudad de Huancané, del distrito y provincia de Huancané, región Puno.

La cuenca de río Huancané tiene una dependencia administrativa del Ministerio de Agricultura, así mismo depende del Instituto Nacional de Recursos Naturales a través de la Intendencia de Recursos Hídricos del INRENA, y de la Dirección Regional Agraria de Puno. Para el manejo de los recursos hídricos, la cuenca se ha dividido en 9 unidades hidrográficas; Las entidades, en orden jerárquico, encargados de la gestión del agua en la cuenca del río Huancané se indica en la Fig. 3.1.

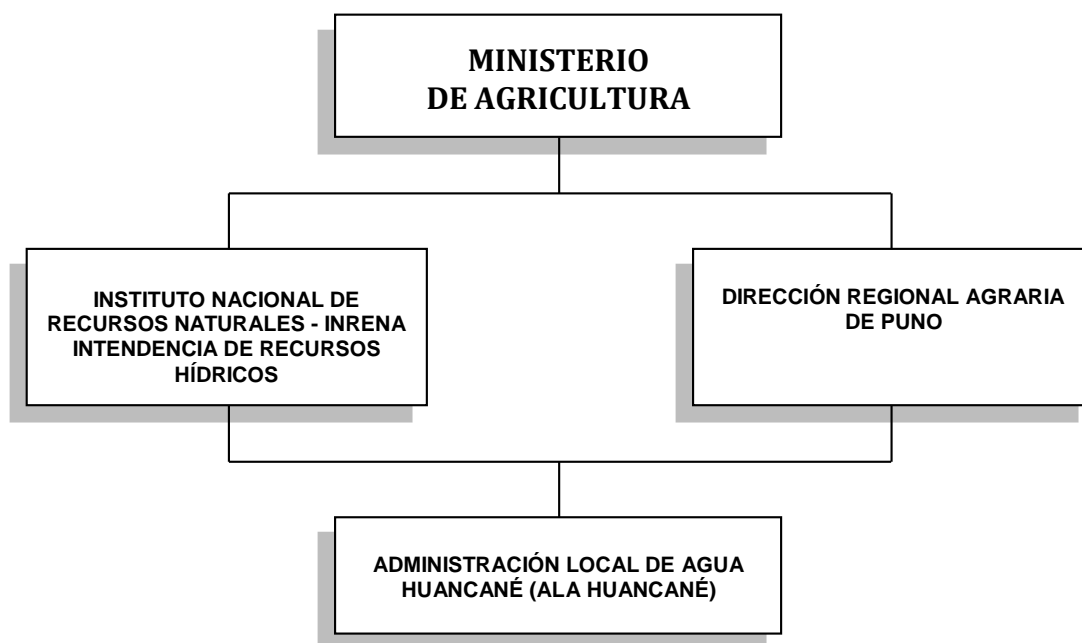


Figura 3.1: Organigrama de la gestión del agua en la cuenca del río Huancané

3.1.1.5. Vías de comunicación y acceso:

La ciudad de Huancané es el centro urbano más relevante de la cuenca Huancané, las vías de acceso en una unidad móvil desde la ciudad de Huancané hacia cualquier lugar de la cuenca es accesible. Las principales vías de acceso a la cuenca Huancané, es la siguiente:

Cuadro N° 3.1: Vías de acceso

N°	TRAMO	DISTANCIA (Km)	TIEMPO (Min)	VIA
1	Puno - Juliaca	45.00	40	Asfaltada
2	Juliaca - Huancané	63.20	60	Asfaltada
3	Huancané - Huatasani	17.91	20	Asfaltada
4	Huatasani - Inchupalla	21.86	25	Trocha
5	Inchupalla - Quilcapunco	24.26	30	Trocha
6	Huatasani - Putina	19.21	25	Asfaltada
7	Putina - Muñani	22.88	25	Trocha

Fuente: Evaluación de Recursos Hídricos, cuenca Huancané ANA 2010

3.1.2. DESCRIPCIÓN GENERAL DE LA CUENCA:

La cuenca hidrográfica del río Huancané, tiene una extensión aproximada de 3631.19 km², desde la partición de agua hasta la desembocadura en el lago Titicaca, presenta una forma más o menos “alargada”. El curso principal nace desde el río Toco Toco - río Ticani - río Puncune - río Pongongoni - río Putina; luego de un largo recorrido el río Putina confluye con el río Tuyto, es a partir de este punto que toma el nombre del río Huancané, nombre con el cual desemboca en el lago Titicaca.

La longitud del cauce principal es aproximadamente de 142 km y tiene una pendiente media de 0.70%. La cuenca del río Huancané está conformado por 09 unidades hidrográficas: Alto Huancané (río Puncune), Pistune (río Pistune), Muñani (río Muñani), Tuyto (río Tuyto), Llache (río Llache), Medio Alto Huancané (río

Pongongoni), Medio Huancané (río Putina), Medio Bajo Huancané (tramo río Huancané) y Bajo Huancané (tramo río Huancané).

La cuenca del río Huancané cuenta actualmente con tres estaciones meteorológicas ubicadas en Muñani, Putina y Huancané y una Estación Hidrométrica en el Puente Huancané todas ellas de propiedad del SENAMHI – Puno, de los cuales obtuvimos datos para la presente investigación.

3.1.3. DESCRIPCIÓN HIDROGRÁFICA DE LA CUENCA:

3.1.3.1. Unidades Hidrográficas Cuenca Río Huancané:

La denominación de la Unidades Hidrográficas circunscritas al área de la cuenca del río Huancané se ha realizado en función de su extensión y nombre de sus cursos de agua finales o ríos; estableciéndose Nueve (09) Unidades Hidrográficas básicas o subcuencas (Cuadro N° 3.2).

El ámbito de la cuenca del río Huancané cuenta con un total de 1 646 fuentes de agua superficial, existe una considerable cantidad de manantiales en la cuenca que representa el 49%. De las 1 646 fuentes de agua superficiales registradas, 481 no tienen ningún uso, 124 de uso poblacional, 537 de uso pecuario, 02 de uso piscícola, 460 son de uso agrícola, 01 de uso minero, 72 son de uso agrícola y pecuario, 05 de uso poblacional y pecuario, 11 de uso agrícola y poblacional.

Cuadro N° 3.2: Unidades hidrográficas de la cuenca río Huancané

N°	Unidad Hidrográfica	Río Principal	código PFAFSTETTER	Perímetro (Km)	Superficie		Longitud Río Principal (Km)	Pendiente Río Principal (%)	N° orden del Río
					Km ²²	%			
1	Bajo Huancané	Tramo Río Huancané	1781	82.84	246.41	6.79	29.99	0.10	6
2	Llache	Río Llache	1782	68.63	161.93	4.46	40.42	2.04	4
3	Medio bajo Huancané	Tramo Río Huancané	1783	40.09	47.94	1.32	10.09	0.07	6
4	Tuyto	Río Tuyto	1784	207.25	1107.11	30.49	94.17	0.49	5
5	Medio Huancané	Río Putina	1785	89.12	231.07	6.36	36.46	0.04	6
6	Muñani	Río Muñani	1786	180.65	889.44	23.97	71.58	1.26	5
7	Medio Alto Huancané	Río Pongongoni	1787	27.58	42.09	1.15	16.17	0.08	6
8	Pistune	Río Pistune	1788	99.54	380.43	10.48	52.53	1.68	5
9	Alto Huancané	Río Puncune	1789	116.55	524.77	14.98	49.34	1.89	5

Fuente: Evaluación de Recursos Hídricos, cuenca Huancané ANA 2010

3.1.3.2. Junta de usuarios del distrito de riego Huancané:

La Junta de Usuarios del Distrito de Riego Huancané es la organización que representa a los agricultores frente a las múltiples instituciones relacionadas al uso de recurso hídrico para la agricultura. La junta de Usuarios Huancané agrupa a más de 219 Comisiones de Regantes en su jurisdicción.

Cuadro N° 3.3: Total de usuarios de Riego en la cuenca Huancané

CUENCA	PROVINCIA	DISTRITO	N° COMITES	N° USUARIO DE RIEGO	AREA
					(Has)
HUANCANÉ	San Antonio de Putina	Putina	19	810	633.90
		Muñani	12	786	900.00
		Quilcapunco	21	727	501.00
		Pedro vilca apaza	6	286	99.00
	Huancané	Huancané	15	690	89.00
		Cojata	41	722	1393.72
		Huatasani	3	86	28.00
		Rosaspata	13	674	178.30
		Vilquechico	22	894	336.00
	Moho	Moho	49	2398	488.00
		Conima	6	434	95.00
	TOTAL			219	8980

Fuente: Junta de Usuarios del Distrito de Riego Huancané 2013.

3.1.4. DESCRIPCIÓN CLIMÁTICA DE LA CUENCA:

3.1.4.1. Precipitación:

La precipitación anual de la cuenca del río Huancané, varía de 430 mm a 870 mm, los valores altos se registraron en el entorno del lago Titicaca, en la parte baja y norte de la cuenca; y los valores menores se registraron en el sur de la cuenca.

3.1.4.2. Temperatura:

La temperatura media de la cuenca varía entre 3.0 °C a 8.0 °C, las temperaturas máximas alcanza hasta 23.4 °C y las mínimas alcanzan valores hasta -11.8 °C, así mismo las regiones más cálidas se encuentran en las zonas de las estaciones Muñani y Putina.

3.1.4.3. Humedad Relativa:

En base a la información histórica disponible de las estaciones meteorológicas, la distribución espacial de la humedad relativa en la cuenca del río Huancané varía entre 22% y 96%.

3.1.4.4. Velocidad del viento:

La velocidad del viento de la cuenca del río Huancané varía entre 2 y 12 m/s.

3.1.4.5. Horas de sol:

Para la cuenca en estudio las horas de sol varía entre 0.1 horas a 12 horas, los mayores valores se registraron en la parte baja y los valores menores en la parte alta de la cuenca.

3.1.4.6. Evaporación:

La distribución espacial de la evaporación total anual de la cuenca del río Huancané, varía entre 1560 mm hasta 1900 mm por año, estos datos generalmente son obtenidos del tanque tipo A.

3.2. MATERIALES:

3.2.1. INFORMACIÓN CARTOGRÁFICA:

Para el presente proyecto de tesis se han utilizado cartas nacionales que abarcan la cuenca del río Huancané, se utilizaron las siguientes hojas de la carta nacional: 30v, 30x, 30y, 31v, 31x, 31y, a escala 1:100,000; elaborados por el Instituto Geográfico Nacional (IGN), las cuales fueron digitalizadas bajo el entorno de SIG con equidistancia mínima entre curvas de nivel de 100 m.

3.2.2. INFORMACIÓN METEOROLÓGICA:

Para la presente Tesis se han utilizado registros meteorológicos correspondientes a 3 estaciones meteorológicas que se encuentran dentro de la cuenca del río Huancané, la información meteorológica fue obtenida de la base de datos del Servicio Nacional de Meteorología e Hidrología (SENAMHI) de Puno; los datos meteorológicos empleados para el presente trabajo están constituidos por registros diarios de:

1. Temperatura mínima
2. Temperatura máxima
3. Humedad relativa media
4. Horas sol
5. Velocidad del viento
6. Evaporación diaria del tanque clase "A".

Cuadro N° 3.7. Periodo de registro de información meteorológica de Temperaturas Máximas.

Año	Periodo de registro de Temperaturas Máximas																																		
	Estación Huancané												Estación Putina												Estación Muñani										
	E	F	M	A	M	J	J	A	S	O	N	D	E	F	M	A	M	J	J	A	S	O	N	D	E	F	M	A	M	J	J	A	S	O	N
2008												*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*
2009												*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*
2010																																			
2011																																			
2012																																			
2013																																			
2014	*	*	*	*	*	*	*	*	*	*	*													*	*	*	*	*	*	*	*	*	*	*	*

Cuadro N° 3.8. Periodo de registro de información meteorológica de Velocidad del Viento.

Año	Periodo de registro de velocidad del Viento																																		
	Estación Huancané												Estación Putina												Estación Muñani										
	E	F	M	A	M	J	J	A	S	O	N	D	E	F	M	A	M	J	J	A	S	O	N	D	E	F	M	A	M	J	J	A	S	O	N
2008												*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*
2009												*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*
2010																																			
2011																																			
2012																																			
2013																																			
2014	*	*	*	*	*	*	*	*	*	*	*													*	*	*	*	*	*	*	*	*	*	*	*

Cuadro N° 3.9. Periodo de registro de información meteorológica de Horas sol.

Año	Periodo de registro de Horas de Sol																																		
	Estación Huancané												Estación Putina												Estación Muñani										
	E	F	M	A	M	J	J	A	S	O	N	D	E	F	M	A	M	J	J	A	S	O	N	D	E	F	M	A	M	J	J	A	S	O	N
2008												*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*
2009												*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*
2010																																			
2011																																			
2012																																			
2013																																			
2014	*	*	*	*	*	*	*	*	*	*	*													*	*	*	*	*	*	*	*	*	*	*	*

Cuadro N° 3.10. Periodo de registro de información meteorológica de Evaporación.

Año	Periodo de registro de Evaporación del Tanque clase A																																		
	Estación Huancané												Estación Putina												Estación Muñani										
	E	F	M	A	M	J	J	A	S	O	N	D	E	F	M	A	M	J	J	A	S	O	N	D	E	F	M	A	M	J	J	A	S	O	N
2008												*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*
2009												*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*	*
2010																																			
2011																																			
2012																																			
2013																																			
2014	*	*	*	*	*	*	*	*	*	*	*													*	*	*	*	*	*	*	*	*	*	*	*

3.2.3. EQUIPOS Y PROGRAMAS DE CÓMPUTO:

Materiales de escritorio:

- Papel bond A4, A3,
- Memoria USB 16 GB
- Tinta de Impresora
- Materiales de escritorio

Materiales y equipos de campo:

- Cartas nacionales
- Cámara fotográfica digital
- GPS Garmin
- Bincha de 5m

Materiales y equipos de gabinete:


- Computadora coreI7, RAM 4 GB, velocidad 3.2 GHz, 500 GB memoria.
- Impresora multifuncional Epson L365 sistema continuo.
- Ploter
- Cartas nacionales
- Fotografías Digitalizadas
- Bibliografía necesaria

Softwares utilizados:

- Arc Gis 9.3
- Microsoft Office Word 2007
- Microsoft Office Excel 2007
- Cropwat 8.0
- Alyuda NeuroIntelligence 2.1
- Matlab R2010a aplicación del toolbox Neural network

3.3. METODOLOGIA:**3.3.1. TIPO DE INVESTIGACIÓN:**

La presente tesis está referido a una investigación DESCRIPTIVA – COMPARATIVA, se considera **Descriptiva – comparativa** dado que se analiza el comportamiento de la ETo estimada con modelos de RNA respecto a los métodos empíricos (Penman Monteith FAO 56, Hargreaveas – Samani (1985) y tanque de evaporación clase A).

3.3.2. DISEÑO DE INVESTIGACIÓN:

Donde:

M1 = Corresponde a la muestra del estudio.

O1 = Observación de la ETo estimada con métodos empíricos.

O2 = Observación de la ETo estimada con Redes Neuronales Artificiales.

Comparar la evapotranspiración de referencia (ETo) estimada por modelos de Redes Neuronales Artificiales en función de variables climáticas con los métodos empíricos (FAO 56 Penman - Monteith, Hargreaveas – Samani (1985) y tanque de evaporación clase A) en la cuenca del río Huancané.

3.3.3. VARIABLES:**Variable Dependiente:**

Estimación de la evapotranspiración de referencia (ETo).

Variable Independiente:

Modelos de Redes Neuronales Artificiales en función de elementos climáticos.

3.3.4. POBLACIÓN Y MUESTRA:

3.3.4.1. Población:

Para el presente estudio se consideró como población al total de datos meteorológicos de la cuenca del río Huancané correspondiente a tres estaciones meteorológicas.

3.3.4.2. Muestra:

Para el presente estudio se consideró como muestra el conjunto de datos recopilados de cada estación. Estos datos son considerados como muestreo aleatorio. Los datos recopilados son registros meteorológicos de 5 años consistentes en: (temperatura mínima, temperatura máxima, Humedad relativa, Horas sol, velocidad de viento y evaporación de tanque clase A), estos datos se procesaron a nivel diario comprendidos desde enero 2008 a diciembre del 2014.

3.3.5. TÉCNICAS E INSTRUMENTOS:

3.3.5.1. Técnicas:

La técnica a emplear es la comparación de la evapotranspiración de referencia estimada con los métodos empíricos y la evapotranspiración de referencia estimada con los modelos de redes neuronales artificiales. Los modelos de RNA adecuados para estimar la evapotranspiración de referencia se definieron mediante la prueba de errores.

3.3.5.1. Instrumentos:

Equipo de computo implementado con el software: Excel, Alyuda NeuroIntelligence 2.1, Matlab R2010a aplicación del toolbox Neural network.

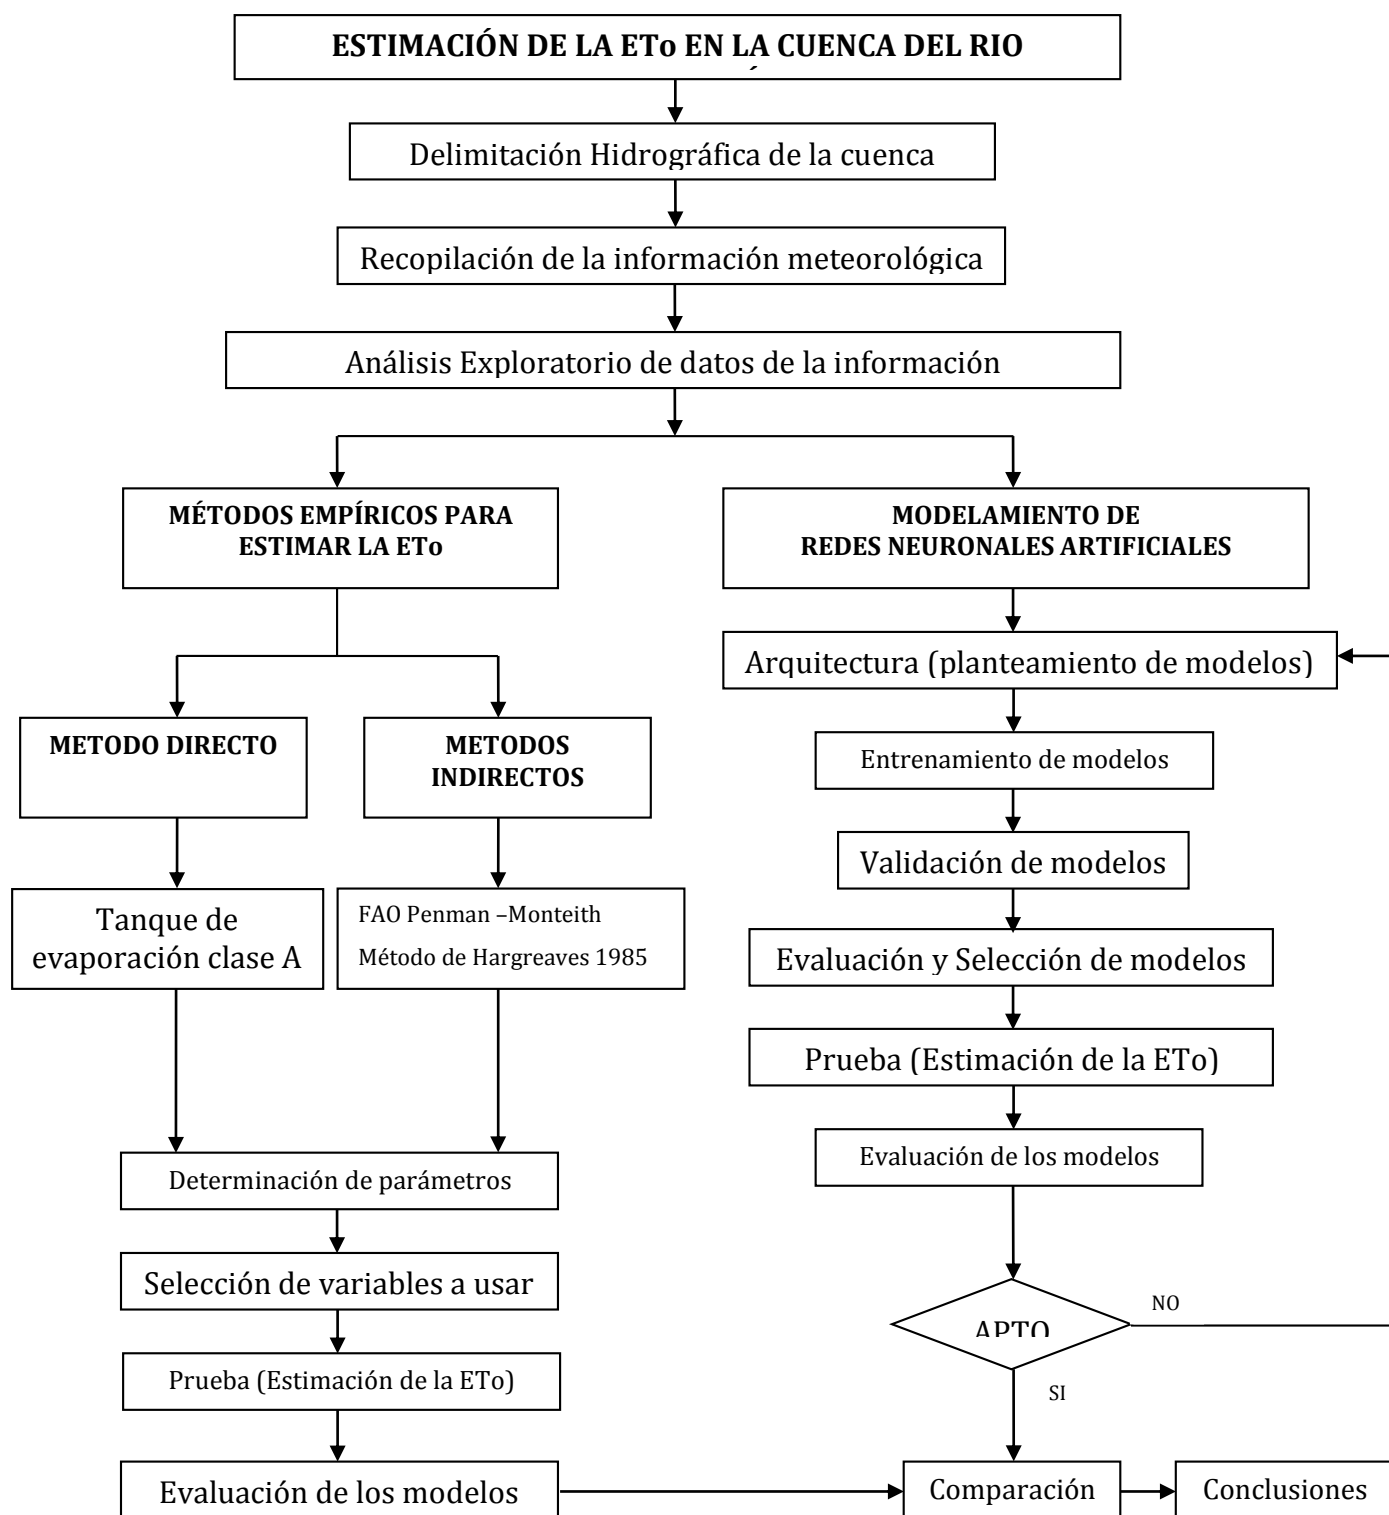
3.3.6. PROCESAMIENTO DE INFORMACIÓN RECOPIADA:

La metodología seguida en el presente trabajo de investigación es:

- ❖ Delimitación de la cuenca hidrográfica.
- ❖ Recopilación de la información meteorológica.
- ❖ Análisis exploratorio de la información meteorológica:
 - ✓ Análisis de datos atípicos de la estación Huancané.
 - ✓ Análisis de datos atípicos de la estación Putina.
 - ✓ Análisis de datos atípicos de la estación Muñani.
- ❖ Estimación de la (ET_o) utilizando métodos empíricos:
 - ✓ Método del tanque de evaporación clase A
 - ✓ Método de FAO Penman - Monteith.
 - ✓ Método Hargreaves – Samani (1985).
- ❖ Modelamiento de redes neuronales artificiales (RNA):
 - ✓ Arquitectura (planteamiento de modelos).
 - ✓ Entrenamiento de modelos.
 - ✓ Validación de modelos.
 - ✓ Evaluación y selección de modelos.
 - ✓ Prueba (estimación de la ET_o)
 - ✓ Evaluación de modelos
- ❖ Comparación de modelos:

3.3.7. DIAGRAMA DE FLUJO DE LA INVESTIGACIÓN:

Figura N° 3.2: Diagrama de flujo de la investigación

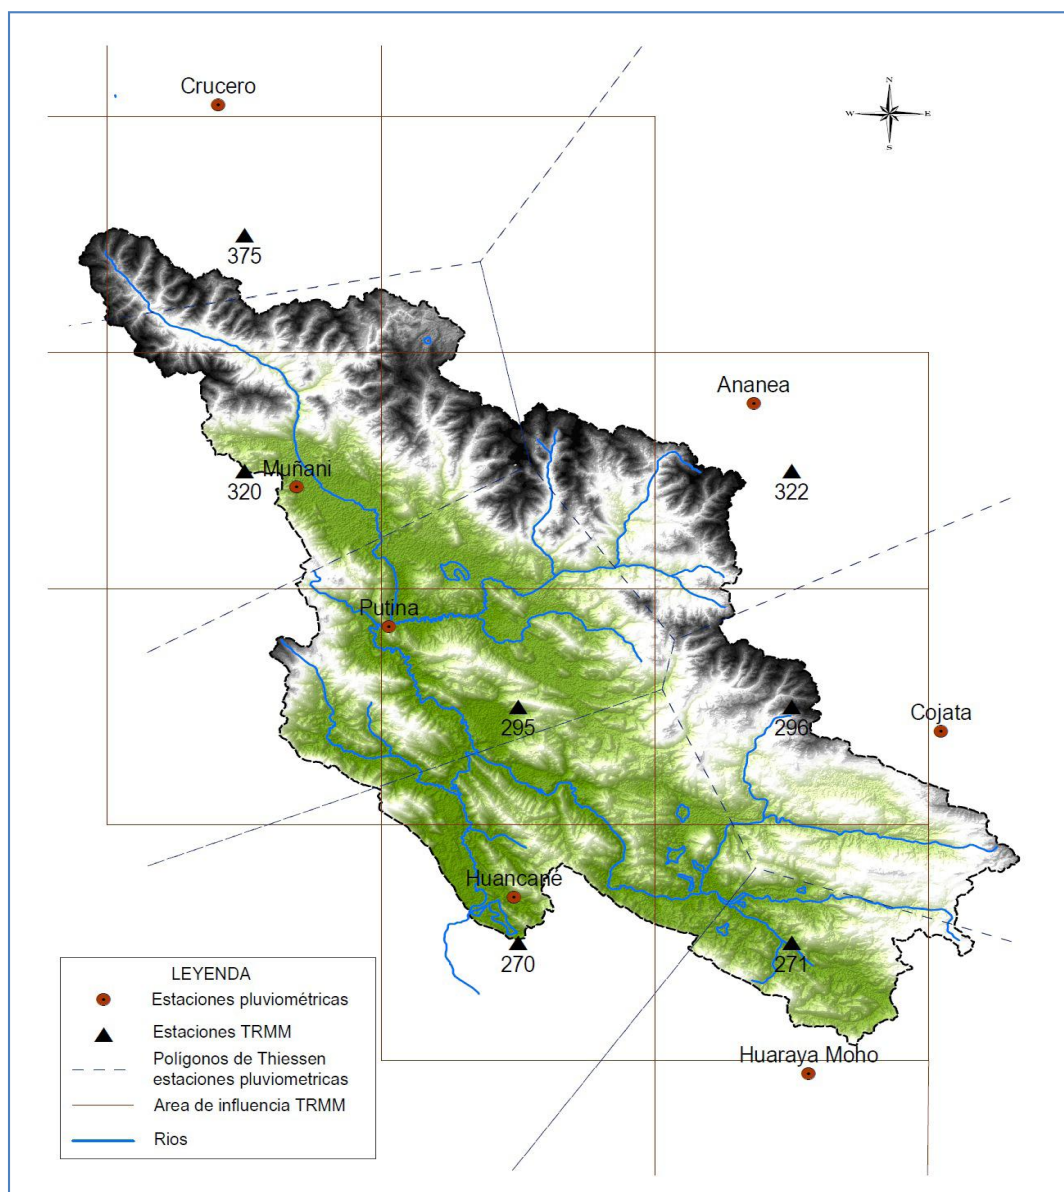


CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

4.1. DELIMITACIÓN HIDROGRÁFICA DE LA CUENCA:

Mapa N° 4.1: Delimitación Hidrográfica de la cuenca Huancané.



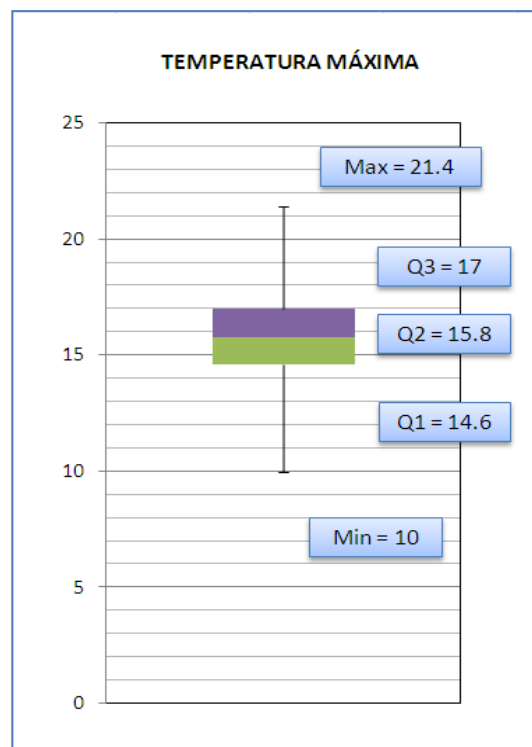

4.2. ANÁLISIS EXPLORATORIO DE LA INFORMACIÓN METEOROLÓGICA:

4.2.1. DIAGRAMA DE CAJAS IDENTIFICACIÓN DE DATOS ATÍPICOS.



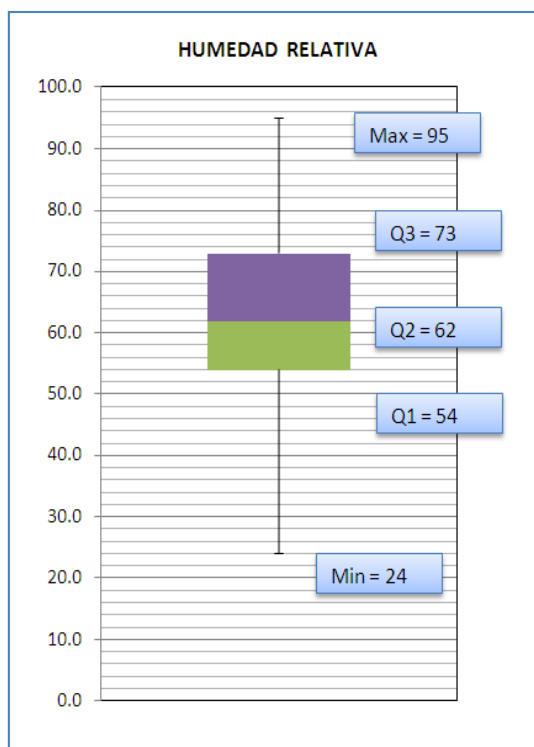
a. Análisis de datos atípicos estación Huancané:

Cuadro N° 4.1: Cuartiles para datos de la estación Huancané.

Tmin	Tmax	HR	Vv	HS	E
Min = -11.6	Min = 10	Min = 24	Min = 2	Min = 0.1	Min = 0.3
Q1 = -3.6	Q1 = 14.6	Q1 = 54	Q1 = 4	Q1 = 6	Q1 = 2.7
Q2 = 1.2	Q2 = 15.8	Q2 = 62	Q2 = 4	Q2 = 9	Q2 = 3.4
Q3 = 4.2	Q3 = 17	Q3 = 73	Q3 = 6	Q3 = 10	Q3 = 4.4
Max = 7.4	Max = 21.4	Max = 95	Max = 12	Max = 12	Max = 8.2



INTERPRETACIÓN: El Diagrama de caja muestra que la mediana está en el centro del rectángulo por lo tanto la distribución de datos es simétrica, lo cual indica que no existe la presencia de valores atípicos en el registro de datos de temperatura mínima y temperatura máxima de la estación meteorológica de Huancané.





INTERPRETACIÓN: El Diagrama de caja muestra que la mediana está en el centro del rectángulo por lo tanto la distribución de datos es simétrica, lo cual indica que no existe la presencia de valores atípicos en el registro de datos de humedad relativa y horas sol de la estación meteorológica de Huancané.





b. Análisis de datos atípicos estación Putina:

Cuadro N° 4.2: Cuartiles para datos de la estación Putina.

Tmin	Tmax	HR	Vv	HS	E
Min = -11.8	Min = 11	Min = 31	Min = 2	Min = 0.3	Min = 0.2
Q1 = -3.5	Q1 = 16.4	Q1 = 60	Q1 = 2	Q1 = 4.4	Q1 = 2.1
Q2 = 1	Q2 = 17.6	Q2 = 67.5	Q2 = 4	Q2 = 7.3	Q2 = 2.8
Q3 = 3.5	Q3 = 18.8	Q3 = 75	Q3 = 6	Q3 = 9.8	Q3 = 3.6
Max = 8.2	Max = 23	Max = 93.5	Max = 11	Max = 11.6	Max = 6.8



INTERPRETACIÓN: El Diagrama de caja muestra que la mediana está en el centro del rectángulo por lo tanto la distribución de datos es simétrica, lo cual indica que no existe la presencia de valores atípicos en el registro de datos de temperatura mínima y temperatura máxima de la estación meteorológica de Putina.





INTERPRETACIÓN: El Diagrama de caja muestra que la mediana está en el centro del rectángulo por lo tanto la distribución de datos es simétrica, lo cual indica que no existe la presencia de valores atípicos en el registro de datos de humedad relativa, velocidad del viento, horas sol y evaporación de la estación meteorológica de Putina.




c. Análisis de datos atípicos estación Muñani:

Cuadro N° 4.3: Cuartiles para datos de la estación Muñani.

Tmin	Tmax	HR	Vv	E
Min = -7	Min = 9.8	Min = 22	Min = 2	Min = 0.1
Q1 = -0.4	Q1 = 15.6	Q1 = 49	Q1 = 2	Q1 = 2.4
Q2 = 2.2	Q2 = 17	Q2 = 59.5	Q2 = 4	Q2 = 3.1
Q3 = 4.4	Q3 = 18.6	Q3 = 70	Q3 = 4	Q3 = 3.9
Max = 7.8	Max = 23.4	Max = 96	Max = 10	Max = 6.8



INTERPRETACIÓN: El Diagrama de caja muestra que la mediana esta en el centro del rectángulo por lo tanto la distribución de datos es simétrica, lo cual indica que no existe la presencia de valores atípicos en el registro de datos de temperatura mínima y temperatura máxima de la estación meteorológica de Muñani.



INTERPRETACIÓN: El Diagrama de caja muestra que la mediana está en el centro del rectángulo por lo tanto la distribución de datos es simétrica, lo cual indica que no existe la presencia de valores atípicos en el registro de datos de humedad relativa, y evaporación de la estación meteorológica de Muñani.

4.3. ESTIMACIÓN DE LA EVAPOTRANSPIRACIÓN DE REFERENCIA:

4.3.1. Métodos empíricos para la estación Huancané:

- Método de FAO 56 Penman - Monteith
- Método Hargreaves – Samani (1985)
- Método del tanque de evaporación clase A

4.3.2. Métodos empíricos para la estación Putina:

- Método de FAO 56 Penman - Monteith
- Método Hargreaves – Samani (1985)
- Método del tanque de evaporación clase A

4.3.3. Métodos empíricos para la estación Muñani:

- Método Hargreaves – Samani (1985)
- Método del tanque de evaporación clase A

Los resultados de la evapotranspiración de referencia (ET_o) utilizando métodos empíricos se presentan en el **ANEXO 4-1**.

4.4. MODELAMIENTO DE REDES NEURONALES ARTIFICIALES (RNA):

El presente trabajo de investigación, dada las características de la zona y considerando que la cuenca del río Huancané cuenta con un número reducido de estaciones meteorológicas, se ha optado por utilizar el 70 % de datos para la fase de entrenamiento, el 15 % de datos para la fase de validación y el 15% de datos para la fase de prueba o estimación de la ET_o, dando mayor énfasis al entrenamiento de la red, por consiguiente la división de datos formados es como se indican en los cuadros N° 4.4, cuadro N° 4.5 y cuadro N° 4.6.

Para el modelamiento de las redes neuronales artificiales (RNA), para la fase de entrenamiento, validación y prueba de los modelos se ha utilizado el programa Alyuda NeuroIntelligence 2.2 version trial, desarrollado por ALYUDA Research Company, este programa permite de una forma rápida escoger el número de neuronas ocultas teniendo como base las entradas y salidas de la red.

Cuadro N° 4.4: Distribución de datos para la estación Huancané.

CONJUNTO DE DATOS	PORCENTAJE	CANTIDAD (Días)	Días	
	%		Desde	Hasta
Entrenamiento	70%	1274	01-ene-08	27-jun-11
Validación	15%	273	28-jun-11	26-mar-12
Prueba	15%	273	27-mar-12	24-dic-12
TOTAL	100%	1820		

Cuadro N° 4.5: Distribución de datos para la estación Putina.

CONJUNTO DE DATOS	PORCENTAJE	CANTIDAD (Días)	Días	
	%		Desde	Hasta
Entrenamiento	70%	1274	01-ene-10	27-jun-13
Validación	15%	273	28-jun-13	27-mar-14
Prueba	15%	273	28-mar-13	25-dic-14
TOTAL	100%	1820		

Cuadro N° 4.6: Distribución de datos para la estación Muñani.

CONJUNTO DE DATOS	PORCENTAJE	CANTIDAD (Días)	Días	
	%		Desde	Hasta
Entrenamiento	70%	770	01-ene-10	09-feb-12
Validación	15%	165	10-feb-12	23-jul-12
Prueba	15%	165	24-jul-12	04-ene-13
TOTAL	100%	1100		

4.4.1. ARQUITECTURA:

El presente trabajo de investigación ha utilizado la “Red Perceptrón Multicapa”, con el tipo de conexión hacia adelante (feedforward), todas las señales neuronales se propagan hacia adelante a través de las capas de la red.

En la práctica no existe una regla definida para establecer el número de neuronas en la capa de entrada, Un procedimiento útil para la selección de las variables relevantes (Masters 1993), consiste en entrenar la red con todas las variables de entrada necesarias y a continuación ir eliminando una variable de entrada cada vez y reentrenar la red hasta obtener resultados óptimos.

4.4.1.1. Planteamiento de modelos:

En este trabajo de investigación se ha planteado 30 modelos de RNA con variables similares al método de FAO 56 Penman Monteith, cuyas variables de entrada (capas de entrada) tienen diferentes combinaciones de elementos climáticos usando (T_{min} , T_{max} , HR, V_v , HS).

Por otra parte también se ha planteado 15 modelos de RNA con variables similares al método de Hargreaves – Samani (1985). Así mismo se ha planteado 11 modelos de RNA con variables similares al método del Tanque de evaporación clase A.

En total se ha planteado 56 modelos de RNA con variables de entrada similares a las que utilizan los métodos empíricos. En los siguientes cuadros se muestran los diferentes modelos de RNA planteados.

Cuadro N° 4.7: Planteamientos de modelos de RNA con variables de entrada similares al método FAO 56 Penman Monteith

N° DE VARIABLES DE ENTRADA	MODELOS	VARIABLE INDEPENDIENTE	VARIABLES INDEPENDIENTES
5	RNA - 1	ETo =	f(Tmin,Tmax,HR,Vv,HS)
4	RNA - 2	ETo =	f(Tmax,HR,Vv,HS)
	RNA - 3	ETo =	f(Tmin,HR,Vv,HS)
	RNA - 4	ETo =	f(Tmin,Tmax,Vv,HS)
	RNA - 5	ETo =	f(Tmin,Tmax,HR,HS)
	RNA - 6	ETo =	f(Tmin,Tmax,HR,Vv)
3	RNA - 7	ETo =	f(Tmax, Vv,HS)
	RNA - 8	ETo =	f(Tmin, Vv,HS)
	RNA - 9	ETo =	f(Tmin, HR,Vv)
	RNA - 10	ETo =	f(HR,Vv,HS)
	RNA - 11	ETo =	f(Tmax, HR, HS)
	RNA - 12	ETo =	f(Tmax, HR, VV)
	RNA - 13	ETo =	f(Tmin,Tmax,HS)
	RNA - 14	ETo =	f(Tmin,Tmax,Vv)
2	RNA - 15	ETo =	f(Tmin,Tmax,HR)
	RNA - 16	ETo =	f(Vv,HS)
	RNA - 17	ETo =	f(HR,HS)
	RNA - 18	ETo =	f(HR,Vv)
	RNA - 19	ETo =	f(Tmax,HS)
	RNA - 20	ETo =	f(Tmax,Vv)
	RNA - 21	ETo =	f(Tmax,HR)
	RNA - 22	ETo =	f(Tmin,HS)
	RNA - 23	ETo =	f(Tmin,Vv)
	RNA - 24	ETo =	f(Tmin,HR)
RNA - 25	ETo =	f(Tmin,Tmax)	
1	RNA - 26	ETo =	f(HS)
	RNA - 27	ETo =	f(Vv)
	RNA - 28	ETo =	f(HR)
	RNA - 29	ETo =	f(Tmax)
	RNA - 30	ETo =	f(Tmin)

Fuente: Elaboración propia.

Cuadro N° 4.8: Planteamientos de modelos de RNA con variables de entrada similares al método Hargreaves – Samani (1985)

N° DE VARIABLES DE ENTRADA	MODELOS	VARIABLE INDEPENDIENTE	VARIABLES INDEPENDIENTES
4	RNA - 31	$ET_o =$	$f(T_{min}, T_{max}, T_{med}, Ra)$
3	RNA - 32	$ET_o =$	$f(T_{max}, T_{med}, Ra)$
	RNA - 33	$ET_o =$	$f(T_{min}, T_{med}, Ra)$
	RNA - 34	$ET_o =$	$f(T_{min}, T_{max}, Ra)$
	RNA - 35	$ET_o =$	$f(T_{min}, T_{max}, T_{med})$
2	RNA - 36	$ET_o =$	$f(T_{min}, T_{max})$
	RNA - 37	$ET_o =$	$f(T_{min}, T_{med})$
	RNA - 38	$ET_o =$	$f(T_{min}, Ra)$
	RNA - 39	$ET_o =$	$f(T_{max}, T_{med})$
	RNA - 40	$ET_o =$	$f(T_{max}, Ra)$
1	RNA - 41	$ET_o =$	$f(T_{med}, Ra)$
	RNA - 42	$ET_o =$	$f(T_{min})$
	RNA - 43	$ET_o =$	$f(T_{max})$
	RNA - 44	$ET_o =$	$f(T_{med})$
	RNA - 45	$ET_o =$	$f(Ra)$

Fuente: Elaboración propia.

Cuadro N° 4.9: Modelos de RNA con variables de entrada similares al método del Tanque de evaporación clase A

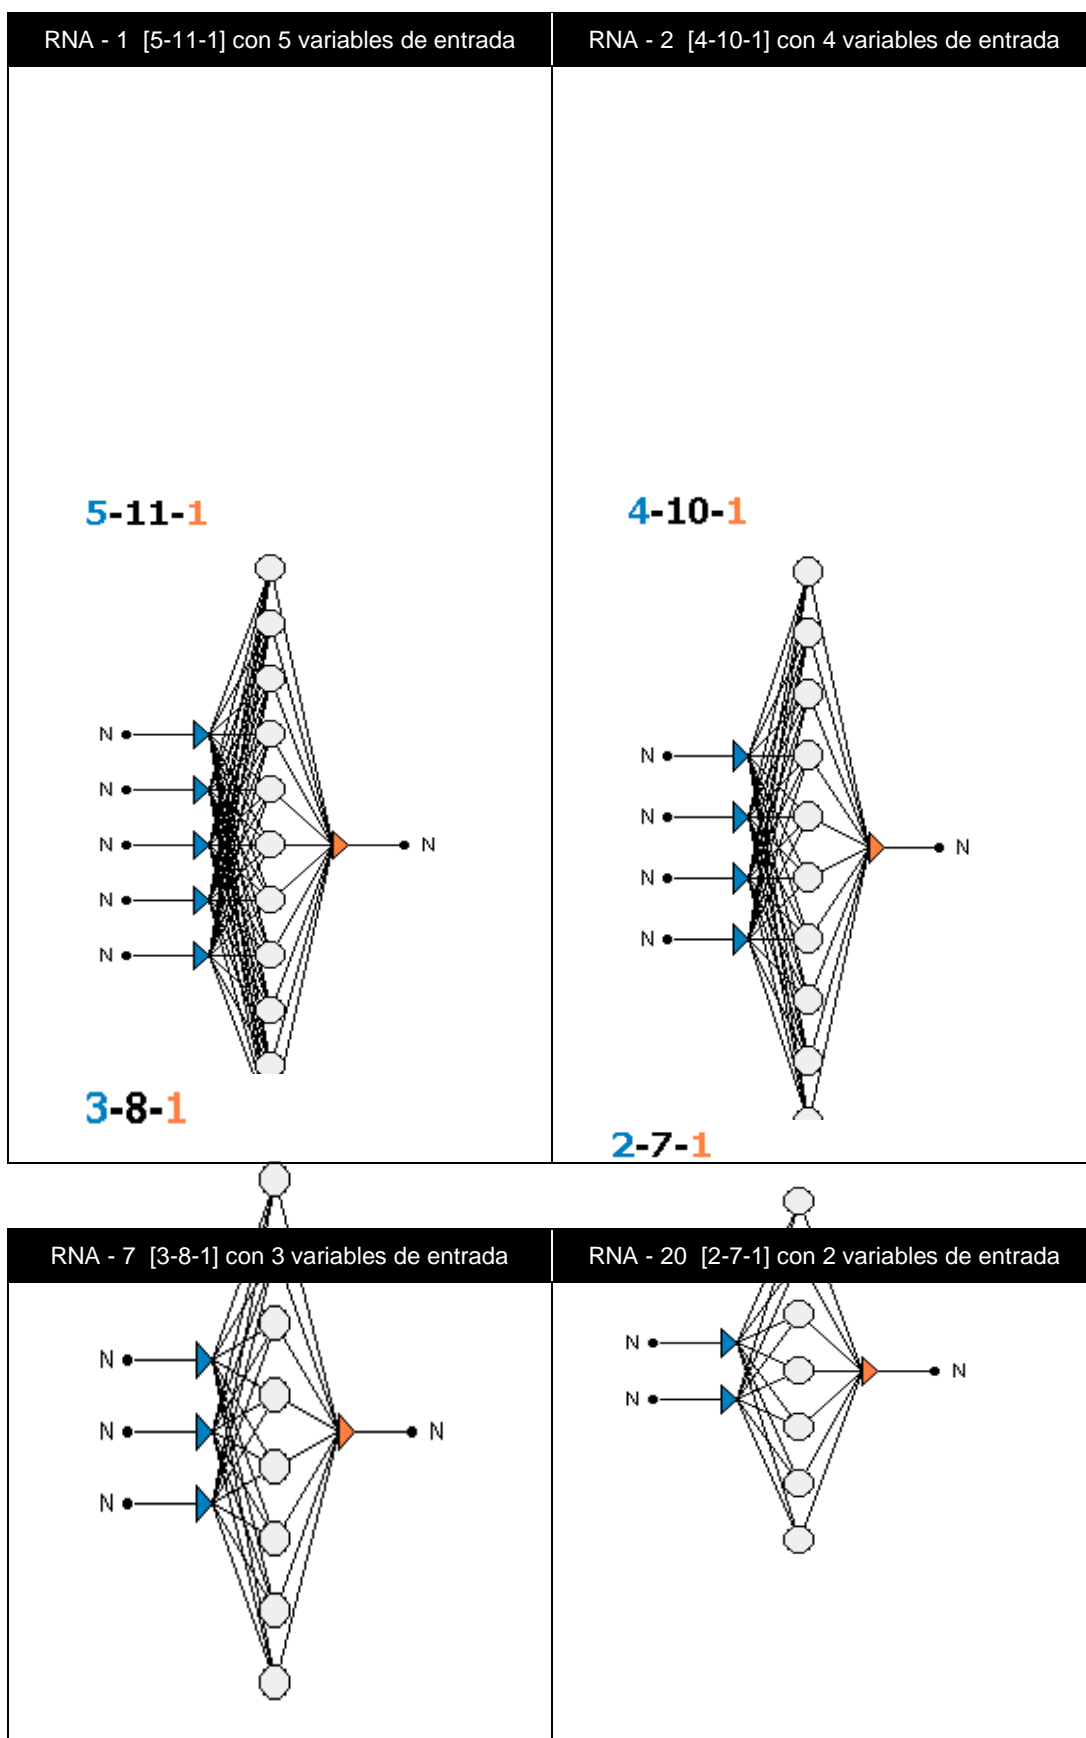
N° DE VARIABLES DE ENTRADA	MODELOS	VARIABLE INDEPENDIENTE	VARIABLES INDEPENDIENTES
4	RNA - 46	$ET_o =$	$f(HR, U_2, K_p, E)$
3	RNA - 47	$ET_o =$	$f(HR, V_v, E)$
	RNA - 48	$ET_o =$	$f(HR, V_v, K_p)$
	RNA - 49	$ET_o =$	$f(V_v, K_p, E)$
2	RNA - 50	$ET_o =$	$f(HR, E)$
	RNA - 51	$ET_o =$	$f(V_v, E)$
	RNA - 52	$ET_o =$	$f(HR, V_v)$
1	RNA - 53	$ET_o =$	$f(HR)$
	RNA - 54	$ET_o =$	$f(V_v)$
	RNA - 55	$ET_o =$	$f(K_p)$
	RNA - 56	$ET_o =$	$f(E)$


Fuente: Elaboración propia.

El número de neuronas de la capa oculta es variable para cada aplicación o modelos planteados y no existe ninguna fórmula que permita definir su cantidad. La mayoría de autores coinciden en que solo la experiencia en el entrenamiento puede proporcionar una idea de cuantas neuronas ocultas es necesario poner en una aplicación específica. En algunos casos puede ser necesario poner más de una capa de neuronas ocultas para poder realizar la aplicación necesaria.

La neurona de salida se encarga de proporcionar la salida del sistema indicado, según su aprendizaje. En los siguientes gráficos se muestra la arquitectura simplificada de los modelos de RNA. La arquitectura de los demás modelos se presenta en el **ANEXO 4-2**.

Figura N° 4.1: Arquitectura simplificada de modelos de RNA con entradas similares al método FAO 56 Penman Monteith





Fuente: Aldyuda neurointelligence versión 2.2

4.4.2. ENTRENAMIENTO DE MODELOS:

Para el entrenamiento de los modelos de RNA, se ha utilizado el 70% de datos disponibles de acuerdo a la cantidad que se ha recolectado para las estaciones meteorológicas de Huancané, Putina y Muñani, según el cuadro N° 4.4, cuadro N° 4.5 y cuadro N° 4.6.

El algoritmo de entrenamiento utilizado para el presente trabajo de investigación es el algoritmo backpropagation, así mismo las características principales para el entrenamiento se describen en el cuadro N° 4.10.

Tasa de aprendizaje:

La tasa de aprendizaje (α) es una constante de proporcionalidad que determina el tamaño del cambio de los pesos. El cambio de los pesos de una neurona es

proporcional al impacto del peso de las neuronas sobre el error, su valor varía entre 0 y 1, siendo 0 un indicador que no haría ningún cambio en el peso, y 1 el que deje pasar todo el valor al nuevo peso. Así un 0.5 atenuaría el cambio del nuevo peso a la mitad.

Momento:

El momento (γ) es un multiplicador que utilizan algunos métodos de entrenamiento para converger al resultado óptimo. El momento describe la porción de cambio de peso que se añade en la siguiente actualización de pesos. El máximo valor para el momento es la unidad y los valores adecuados se eligen de acuerdo al entrenamiento hasta obtener resultados óptimos.

Cuadro N° 4.10: Características principales para el entrenamiento de RNA.

ENTRENAMIENTO DE REDES NEURONALES ARTIFICIALES (RNA)	
Entradas	Tmin, T max, HR, Vv, HS
Arquitectura	Perceptron multicapa
Tipo de conexión	Feed - forward (Hacia delante)
Capas ocultas	Monocapa (1)
Neuronas en la capa oculta	desde 2 neuronas hasta 13 neuronas
Neuronas en la capa de salida	1
Función de activación	logística sigmoidea
Algoritmo de aprendizaje	Supervisado
Tipo de aprendizaje	Aprendizaje por corrección de error
Tasa de aprendizaje	0.1
Factor momento	0.1
Algoritmo de entrenamiento	Backpropagation
Salida	ETo (mm/ día)

4.4.3. VALIDACIÓN DE MODELOS:

Para esta fase se ha realizado la simulación con todos los modelos planteados según los cuadros de planteamientos de modelos. El proceso se efectuó con el 15 % de datos disponibles para cada una de las estaciones meteorológicas de Huancané, Putina y Muñani según el cuadro N° 4.4, cuadro N° 4.5 y cuadro N° 4.6, Por lo tanto para la evaluación de estos modelos se considero como principal evaluador al coeficiente de determinación (R^2), por consiguiente para conocer los resultado se ha utilizado los valores observados de evapotranspiración de referencia (ET_o) calculado con los métodos empíricos y los valores estimados por los diferentes modelos de RNA, comparando un único valor imprescindible conocido como evapotranspiración de referencia (ET_o).

4.4.3.1. RESULTADOS FASE DE VALIDACIÓN:

RESULTADOS DE LA FASE DE VALIDACIÓN DE MODELOS DE RNA CON VARIABLES SIMILARES A FAO 56 PENMAN – MONTEITH

Resultados de la estación Huancané – Fase Validación:

Cuadro N° 4.11: Estadísticos de la Fase de Validación de modelos de RNA con 5 - 4 variables comparados con el Método FAO 56 Penman Monteith.

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
5	RNA - 1	f(Tmin,Tmax,HR,Vv,HS)	[5-11-1]	0.09751	10.2399	89.72	95.97	97.96
4	RNA - 3	f(Tmin,HR,Vv,HS)	[4-2-1]	0.14011	14.7132	85.23	90.75	95.26
	RNA - 2	f(Tmax,HR,Vv,HS)	[4-10-1]	0.21285	22.3509	77.57	89.48	94.59
	RNA - 4	f(Tmin,Tmax,Vv,HS)	[4-4-1]	0.19605	20.5873	79.34	89.20	94.45
	RNA - 5	f(Tmin,Tmax,HR,HS)	[4-4-1]	0.17365	18.2353	81.70	88.14	93.88
	RNA - 6	f(Tmin,Tmax,HR,Vv)	[4-4-1]	0.15568	16.3482	83.59	87.02	93.29

Cuadro N° 4.12: Estadísticos de la Fase de Validación de modelos de RNA con 3 variables comparados con el Método FAO 56 Penman Monteith.

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
3	RNA - 7	f(Tmax, Vv,HS)	[3-8-1]	0.22103	23.2103	76.70	89.67	94.69
	RNA - 12	f(Tmax, HR, VV)	[3-4-1]	0.18246	19.1606	80.77	84.82	92.10
	RNA - 15	f(Tmin,Tmax,HR)	[3-5-1]	0.23078	24.2344	75.68	81.32	90.18
	RNA - 13	f(Tmin,Tmax,HS)	[3-1-1]	0.26543	27.8724	72.03	80.52	89.73
	RNA - 9	f(Tmin, HR, Vv)	[3-3-1]	0.21649	22.7332	77.18	79.60	89.22
	RNA - 11	f(Tmax, HR, HS)	[3-2-1]	0.27468	28.8440	71.05	79.34	89.07
	RNA - 10	f(HR,Vv,HS)	[3-8-1]	0.41036	43.0913	56.75	78.42	88.56
	RNA - 14	f(Tmin,Tmax,Vv)	[3-7-1]	0.36499	38.3276	61.53	78.20	88.43
	RNA - 8	f(Tmin, Vv,HS)	[3-5-1]	0.46107	48.4170	51.41	74.05	86.05

Cuadro N° 4.13: Estadísticos de la Fase de Validación de modelos de RNA con 2 variables comparados con el Método FAO 56 Penman Monteith.

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
2	RNA - 20	f(Tmax,Vv)	[2-7-1]	0.31752	33.3432	66.53	78.00	88.32
	RNA - 19	f(Tmax,HS)	[2-2-1]	0.32998	34.6514	65.22	77.91	88.27
	RNA - 24	f(Tmin,HR)	[2-4-1]	0.30795	32.3381	67.54	76.99	87.74
	RNA - 21	f(Tmax,HR)	[2-6-1]	0.27031	28.3849	71.51	76.05	87.21
	RNA - 16	f(Vv,HS)	[2-7-1]	0.52266	54.8844	44.91	75.96	87.16
	RNA - 17	f(HR,HS)	[2-6-1]	0.29067	30.5230	69.36	73.78	85.89
	RNA - 25	f(Tmin,Tmax)	[2-3-1]	0.36285	38.1030	61.76	72.39	85.08
	RNA - 22	f(Tmin,HS)	[2-7-1]	0.56513	59.3437	40.44	68.76	82.92
	RNA - 18	f(HR,Vv)	[2-3-1]	0.37336	39.2060	60.65	66.39	81.48
	RNA - 23	f(Tmin,Vv)	[2-7-1]	0.92484	97.1169	2.53	28.46	53.35

Cuadro N° 4.14: Estadísticos de la Fase de Validación de modelos de RNA con 1 variables comparados con el Método FAO 56 Penman Monteith.

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
1	RNA - 29	f(Tmax)	[1-5-1]	0.43992	46.1955	53.63	68.94	83.03
	RNA - 28	f(HR)	[1-2-1]	0.47709	50.0986	49.72	59.82	77.34
	RNA - 26	f(HS)	[1-5-1]	0.78230	82.1490	17.55	55.65	74.60
	RNA - 27	f(Vv)	[1-7-1]	0.87026	91.3859	8.28	18.33	42.81
	RNA - 30	f(Tmin)	[1-7-1]	0.90546	95.0821	4.57	17.21	41.49

Grafico N° 4.1: Diagrama de dispersión modelo de RNA - 1 con 5 variables comparado con FAO 56 PM – Fase de Validación.





Grafico N° 4.2: Diagrama de dispersión modelo de RNA - 3 con 4 variables comparado con FAO 56 PM – Fase de Validación.



Resultados de la estación Putina – Fase Validación:

Cuadro N° 4.15: Estadísticos de la Fase de Validación de modelos de RNA con 5 - 4 variables comparados con el Método FAO 56 Penman Monteith.

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
5	RNA - 1	f(Tmin,Tmax,HR,Vv,HS)	[5-11-1]	0.20459	41.9806	57.87	86.21	92.85
4	RNA - 4	f(Tmin,Tmax,Vv,HS)	[4-4-1]	0.25725	52.7863	47.02	77.70	88.15
	RNA - 2	f(Tmax,HR,Vv,HS)	[4-10-1]	0.15671	32.1563	67.73	75.84	87.08
	RNA - 5	f(Tmin,Tmax,HR,HS)	[4-4-1]	0.25665	52.6636	47.14	70.63	84.04
	RNA - 3	f(Tmin,HR,Vv,HS)	[4-2-1]	0.23072	47.3417	52.48	66.44	81.51
	RNA - 6	f(Tmin,Tmax,HR,Vv)	[4-4-1]	0.25589	52.5082	47.30	62.35	78.96

Cuadro N° 4.16: Estadísticos de la Fase de Validación de modelos de RNA con 3 variables comparados con el Método FAO 56 Penman Monteith.

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
3	RNA - 7	f(Tmax, Vv,HS)	[3-8-1]	0.18950	38.8837	60.97	71.14	84.35
	RNA - 11	f(Tmax, HR, HS)	[3-2-1]	0.31821	65.2954	34.46	62.09	78.80
	RNA - 13	f(Tmin,Tmax,HS)	[3-1-1]	0.33089	67.8964	31.85	62.03	78.76
	RNA - 12	f(Tmax, HR, Vv)	[3-4-1]	0.27936	57.3232	42.47	59.97	77.44
	RNA - 10	f(HR,Vv,HS)	[3-8-1]	0.29602	60.7424	39.03	54.15	73.59
	RNA - 15	f(Tmin,Tmax,HR)	[3-5-1]	0.28012	57.4803	42.31	51.09	71.48
	RNA - 9	f(Tmin, HR,Vv)	[3-3-1]	0.28454	58.3856	41.40	46.72	68.35
	RNA - 14	f(Tmin,Tmax,Vv)	[3-7-1]	0.29465	60.4601	39.32	44.10	66.40
	RNA - 8	f(Tmin, Vv,HS)	[3-5-1]	0.39255	80.5487	19.16	42.90	65.50

Cuadro N° 4.17: Estadísticos de la Fase de Validación de modelos de RNA con 2 variables comparados con el Método FAO 56 Penman Monteith.

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
2	RNA - 19	f(Tmax,HS)	[2-2-1]	0.29162	59.8399	39.94	60.85	78.01
	RNA - 21	f(Tmax,HR)	[2-6-1]	0.30866	63.3355	36.43	48.22	69.44
	RNA - 17	f(HR,HS)	[2-6-1]	0.30281	62.1350	37.64	47.21	68.71
	RNA - 20	f(Tmax,Vv)	[2-7-1]	0.33149	68.0193	31.73	43.71	66.11
	RNA - 18	f(HR,Vv)	[2-3-1]	0.34385	70.5568	29.18	42.71	65.35
	RNA - 16	f(Vv,HS)	[2-7-1]	0.36561	75.0220	24.70	39.70	63.01
	RNA - 24	f(Tmin,HR)	[2-4-1]	0.35324	72.4835	27.25	37.34	61.11
	RNA - 25	f(Tmin,Tmax)	[2-3-1]	0.36168	74.2151	25.51	35.03	59.19
	RNA - 22	f(Tmin,HS)	[2-7-1]	0.41202	84.5440	15.15	34.51	58.74
	RNA - 23	f(Tmin,Vv)	[2-7-1]	0.54759	112.3620	-12.78	9.03	30.05

Cuadro N° 4.18: Estadísticos de la Fase de Validación de modelos de RNA con 1 variable comparado con el Método FAO 56 Penman Monteith.

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
1	RNA - 29	f(Tmax)	[1-5-1]	0.33495	68.7296	31.02	36.44	60.37
	RNA - 26	f(HS)	[1-5-1]	0.47134	96.7161	2.93	33.56	57.93
	RNA - 28	f(HR)	[1-2-1]	0.39689	81.4399	18.26	32.51	57.02
	RNA - 27	f(Vv)	[1-7-1]	0.50531	103.6864	-4.07	6.10	24.70
	RNA - 30	f(Tmin)	[1-7-1]	0.54236	111.2898	-11.70	2.40	15.50

Grafico N° 4.3: Diagrama de dispersión modelo de RNA - 1 con 5 variables comparado con FAO 56 PM – Fase de Validación.





Grafico N° 4.4: Diagrama de dispersión modelo de RNA - 4 con 4 variables comparado con FAO 56 PM – Fase de Validación.



RESULTADOS DE LA FASE DE VALIDACIÓN DE MODELOS DE RNA CON
VARIABLES SIMILARES A HARGREAVES - SAMANI (1985)

Resultados de la estación Huancané – Fase Validación:

Cuadro N° 4.19: Estadísticos de la Fase de Validación de modelos de RNA con 4 - 3 variables comparados con el Método Hargreaves - Samani (1985).

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
4	RNA - 31	f(Tmin,Tmax,Tmed, Ra)	[4-4-1]	0.00088	0.2768	99.72	99.73	99.87
3	RNA - 34	f(Tmin,Tmax,Ra)	[3-8-1]	0.00110	0.3462	99.65	99.67	99.84
	RNA - 32	f(Tmax,Tmed, Ra)	[3-7-1]	0.00127	0.4014	99.60	99.64	99.82
	RNA - 33	f(Tmin,Tmed, Ra)	[3-8-1]	0.00165	0.5214	99.48	99.51	99.76
	RNA - 35	f(Tmin,Tmax,Tmed)	[3-2-1]	0.14044	44.2578	55.58	76.86	87.67

Cuadro N° 4.20: Estadísticos de la Fase de Validación de modelos de RNA con 2 variables comparados con el Método Hargreaves - Samani (1985).

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
2	RNA - 40	f(Tmax, Ra)	[2-7-1]	0.01912	6.0255	93.95	96.22	98.09
	RNA - 36	f(Tmin,Tmax)	[2-5-1]	0.12814	40.3826	59.47	80.33	89.63
	RNA - 39	f(Tmax,Tmed)	[2-4-1]	0.12187	38.4065	61.45	80.07	89.48
	RNA - 37	f(Tmin, Tmed)	[2-5-1]	0.18534	58.4079	41.38	77.95	88.29
	RNA - 38	f(Tmin, Ra)	[2-4-1]	0.12980	40.9053	58.94	59.17	76.92
	RNA - 41	f(Tmed, Ra)	[2-2-1]	0.20679	65.1670	34.59	41.25	64.22

Cuadro N° 4.21: Estadísticos de la Fase de Validación de modelos de RNA con 1 variables comparados con el Método Hargreaves - Samani (1985).

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
1	RNA - 43	f(Tmax)	[1-5-1]	0.17915	56.4557	43.34	68.11	82.53
	RNA - 44	f(Tmed)	[1-7-1]	0.33860	106.7047	-7.10	41.19	64.18
	RNA - 45	f(Ra)	[1-2-1]	0.23945	75.4604	24.26	34.51	58.75
	RNA - 42	f(Tmin)	[1-7-1]	0.32587	102.6923	-3.07	21.46	46.32

Grafico N° 4.5: Diagrama de dispersión modelo de RNA - 31 con 4 variables comparado con Hargreaves - Samani (1985) – Fase de Validación.

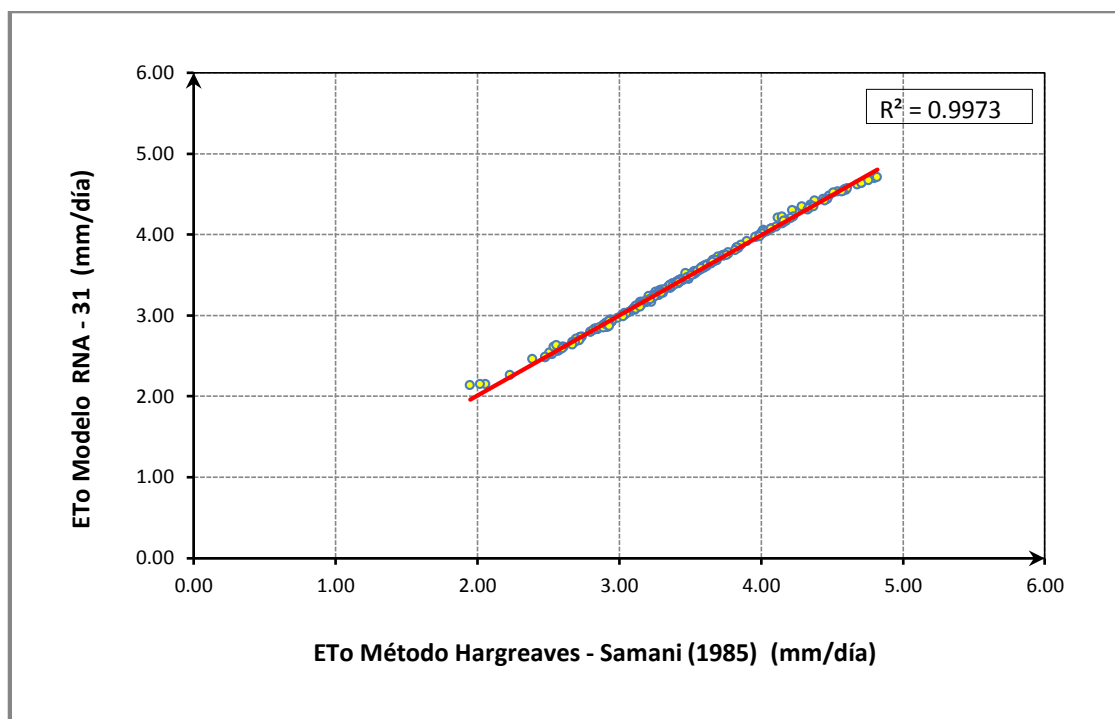



Grafico N° 4.6: Diagrama de dispersión modelo de RNA - 34 con 3 variables comparado con Hargreaves - Samani (1985) – Fase de Validación.



Resultados de la estación Putina – Fase Validación:

Cuadro N° 4.22: Estadísticos de la Fase de Validación de modelos de RNA con 4 - 3 variables comparados con el Método Hargreaves - Samani (1985).

N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
4	RNA - 31	f(Tmin, Tmax, Tmed, Ra)	[4-4-1]	0.00040	0.1126	99.89	99.90	99.95
3	RNA - 32	f(Tmax, Tmed, Ra)	[3-7-1]	0.00057	0.1604	99.84	99.85	99.93
	RNA - 34	f(Tmin, Tmax, Ra)	[3-8-1]	0.00122	0.3403	99.66	99.70	99.85
	RNA - 33	f(Tmin, Tmed, Ra)	[3-8-1]	0.00157	0.4383	99.56	99.63	99.82
	RNA - 35	f(Tmin, Tmax, Tmed)	[3-2-1]	0.29390	82.0559	17.64	71.13	84.34

Cuadro N° 4.23: Estadísticos de la Fase de Validación de modelos de RNA con 2 variables comparados con el Método Hargreaves - Samani (1985).

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
2	RNA - 40	f(Tmax, Ra)	[2-7-1]	0.02045	5.7093	94.27	95.78	97.87
	RNA - 37	f(Tmin, Tmed)	[2-5-1]	0.20494	57.2183	42.57	73.99	86.02
	RNA - 39	f(Tmax, Tmed)	[2-4-1]	0.19200	53.6072	46.20	71.08	84.31
	RNA - 36	f(Tmin, Tmax)	[2-5-1]	0.27994	78.1602	21.55	71.01	84.27
	RNA - 38	f(Tmin, Ra)	[2-4-1]	0.14483	40.4365	59.41	61.53	78.44
	RNA - 41	f(Tmed, Ra)	[2-2-1]	0.23513	65.6470	34.11	56.21	74.97

Cuadro N° 4.24: Estadísticos de la Fase de Validación de modelos de RNA con 1 variables comparados con el Método Hargreaves - Samani (1985).

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
1	RNA - 43	f(Tmax)	[1-5-1]	0.42080	117.4882	-17.92	55.66	74.61
	RNA - 45	f(Ra)	[1-2-1]	0.21854	61.0174	38.76	52.64	72.55
	RNA - 44	f(Tmed)	[1-7-1]	0.36548	102.0426	-2.42	46.16	67.94
	RNA - 42	f(Tmin)	[1-7-1]	0.45966	128.3375	-28.81	25.27	50.27

Grafico N° 4.7: Diagrama de dispersión modelo de RNA - 31 con 4 variables comparado con Hargreaves - Samani (1985) – Fase de Validación.





Grafico N° 4.8: Diagrama de dispersión modelo de RNA - 32 con 3 variables comparado con Hargreaves - Samani (1985) – Fase de Validación.



Resultados de la estación Muñani – Fase Validación:

Cuadro N° 4.25: Estadísticos de la Fase de Validación de modelos de RNA con 4 - 3 variables comparados con el Método Hargreaves - Samani (1985).

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
4	RNA - 31	f(Tmin,Tmax,Tmed, Ra)	[4-4-1]	0.00142	0.4096	99.59	99.00	99.50
3	RNA - 33	f(Tmin,Tmed, Ra)	[3-8-1]	0.00221	0.6367	99.36	98.54	99.27
	RNA - 32	f(Tmax,Tmed, Ra)	[3-7-1]	0.00564	1.6221	98.37	95.44	97.69
	RNA - 34	f(Tmin,Tmax,Ra)	[3-8-1]	0.00720	2.0706	97.92	94.38	97.15
	RNA - 35	f(Tmin,Tmax,Tmed)	[3-2-1]	0.17188	49.4548	50.24	40.25	63.45

Cuadro N° 4.26: Estadísticos de la Fase de Validación de modelos de RNA con 2 variables comparados con el Método Hargreaves - Samani (1985).

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
2	RNA - 40	f(Tmax, Ra)	[2-7-1]	0.00839	2.4127	97.57	93.01	96.44
	RNA - 38	f(Tmin, Ra)	[2-4-1]	0.10804	31.0864	68.72	47.99	69.28
	RNA - 39	f(Tmax,Tmed)	[2-4-1]	0.14340	41.2605	58.49	45.81	67.68
	RNA - 37	f(Tmin, Tmed)	[2-5-1]	0.19519	56.1616	43.50	38.89	62.36
	RNA - 41	f(Tmed, Ra)	[2-2-1]	0.17812	51.2500	48.44	38.54	62.08
	RNA - 36	f(Tmin,Tmax)	[2-5-1]	0.20735	59.6610	39.98	37.08	60.89

Cuadro N° 4.27: Estadísticos de la Fase de Validación de modelos de RNA con 1 variables comparados con el Método Hargreaves - Samani (1985).

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
1	RNA - 44	f(Tmed)	[1-7-1]	0.18623	53.5829	46.09	36.04	60.03
	RNA - 45	f(Ra)	[1-2-1]	0.19323	55.5975	44.06	31.82	56.41
	RNA - 43	f(Tmax)	[1-5-1]	0.40428	116.3214	-17.03	19.63	44.31
	RNA - 42	f(Tmin)	[1-7-1]	0.56112	161.4481	-62.43	12.27	35.03

Grafico N° 4.9: Diagrama de dispersión modelo de RNA - 31 con 4 variables comparado con Hargreaves - Samani (1985) – Fase de Validación.

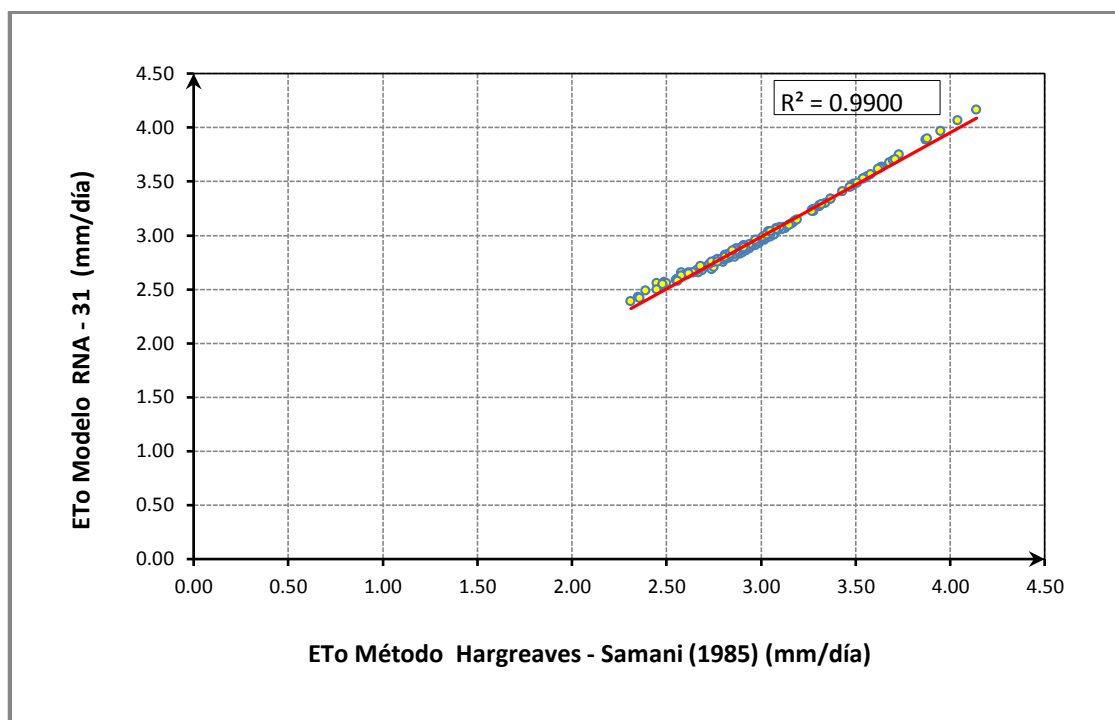



Grafico N° 4.10: Diagrama de dispersión modelo de RNA - 33 con 3 variables comparado con Hargreaves - Samani (1985) – Fase de Validación.



RESULTADOS DE LA FASE DE VALIDACIÓN DE MODELOS DE RNA CON
VARIABLES SIMILARES AL TANQUE DE EVAPORACIÓN CLASE A

Resultados de la estación Huancané – Fase Validación:

Cuadro N° 4.28: Estadísticos de la Fase de Validación de modelos de RNA con 4 - 3 variables comparados con el Método del Tanque clase A.

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
4	RNA - 46	f(HR, U2, Kp, E)	[4-8-1]	0.00252	0.2771	99.72	99.73	99.86
3	RNA - 49	f(Vv, Kp, E)	[3-8-1]	0.00274	0.3013	99.70	99.72	99.86
	RNA - 47	f(HR, Vv, E)	[3-5-1]	0.00590	0.6498	99.35	99.42	99.71
	RNA - 48	f(HR, Vv, Kp)	[3-5-1]	0.68334	75.2352	24.49	35.14	59.28

Cuadro N° 4.29: Estadísticos de la Fase de Validación de modelos de RNA con 2 variables comparados con el Método del Tanque clase A.

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
2	RNA - 51	f(Vv, E)	[2-6-1]	0.01266	1.3941	98.60	98.65	99.32
	RNA - 50	f(HR, E)	[2-7-1]	0.04198	4.6215	95.36	95.37	97.66
	RNA - 52	f(HR, Vv)	[2-7-1]	0.69493	76.5113	23.21	35.08	59.23

Cuadro N° 4.30: Estadísticos de la Fase de Validación de modelos de RNA con 1 variables comparados con el Método del Tanque clase A.

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
1	RNA - 56	f(E)	[1-2-1]	0.05211	5.7370	94.24	94.39	97.15
	RNA - 53	f(HR)	[1-7-1]	0.72852	80.2090	19.50	36.23	60.19
	RNA - 55	f(Kp)	[1-4-1]	0.86979	95.7630	3.88	14.85	38.53
	RNA - 54	f(Vv)	[1-7-1]	0.95288	104.9107	-5.30	9.03	30.05

Grafico N° 4.11: Diagrama de dispersión modelo de RNA - 46 con 4 variables comparado con el Método del Tanque de Evaporación clase A – Fase de Validación.


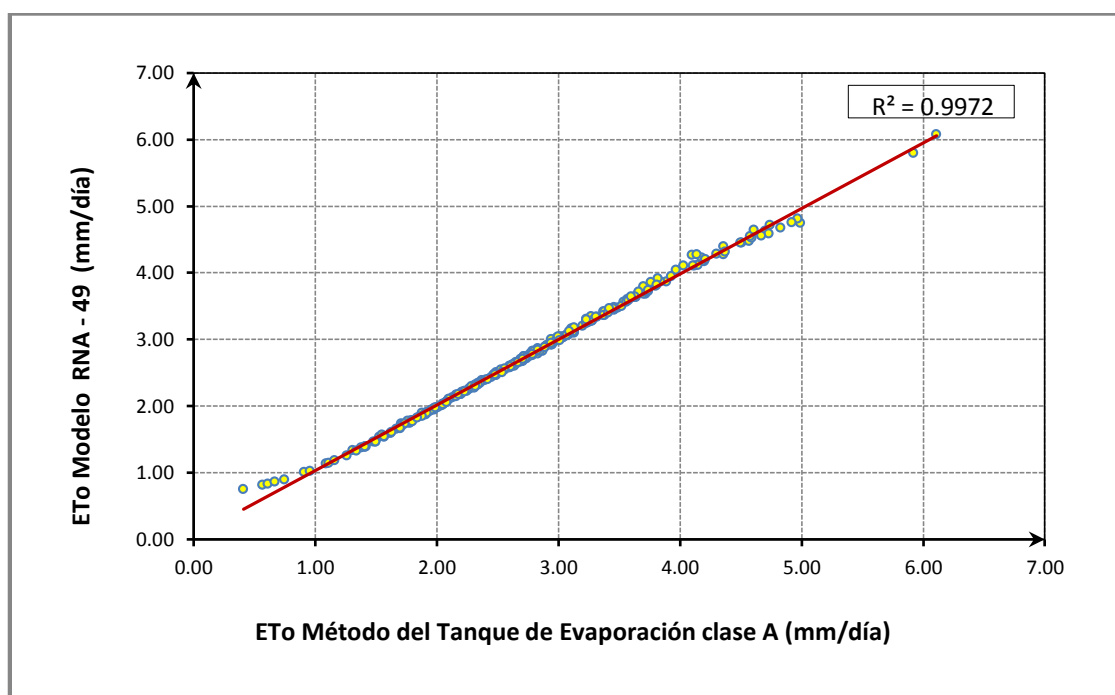


Grafico N° 4.12: Diagrama de dispersión modelo de RNA - 49 con 3 variables comparado con el Método del Tanque de Evaporación clase A – Fase de Validación.



Resultados de la estación Putina – Fase Validación:

Cuadro N° 4.31: Estadísticos de la Fase de Validación de modelos de RNA con 4 - 3 variables comparados con el Método del Tanque clase A.

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
4	RNA - 46	f(HR, U2, Kp, E)	[4-8-1]	0.02580	2.8551	97.13	97.19	98.59
3	RNA - 49	f(Vv, Kp, E)	[3-8-1]	0.03172	3.5105	96.48	96.65	98.31
	RNA - 47	f(HR, Vv, E)	[3-5-1]	0.03209	3.5510	96.44	96.63	98.30
	RNA - 48	f(HR, Vv, Kp)	[3-5-1]	0.92474	102.3429	-2.72	6.26	25.02

Cuadro N° 4.32: Estadísticos de la Fase de Validación de modelos de RNA con 2 variables comparados con el Método del Tanque clase A.

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
2	RNA - 51	f(Vv, E)	[2-6-1]	0.03325	3.6801	96.31	96.48	98.22
	RNA - 50	f(HR, E)	[2-7-1]	0.05167	5.7188	94.26	94.48	97.20
	RNA - 52	f(HR, Vv)	[2-7-1]	0.94858	104.9811	-5.37	7.80	27.93

Cuadro N° 4.33: Estadísticos de la Fase de Validación de modelos de RNA con 1 variables comparados con el Método del Tanque clase A.

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
1	RNA - 56	f(E)	[1-2-1]	0.05331	5.9004	94.08	94.35	97.13
	RNA - 54	f(Vv)	[1-7-1]	0.99690	110.3293	-10.73	5.40	23.24
	RNA - 53	f(HR)	[1-7-1]	0.97737	108.1672	-8.56	2.53	15.92
	RNA - 55	f(Kp)	[1-4-1]	1.00558	111.2892	-11.70	1.09	10.45

Grafico N° 4.13: Diagrama de dispersión modelo de RNA - 46 con 4 variables comparado con el Método del Tanque de Evaporación clase A – Fase de Validación.





Grafico N° 4.14: Diagrama de dispersión modelo de RNA - 49 con 3 variables comparado con el Método del Tanque de Evaporación clase A – Fase de Validación.



Resultados de la estación Muñani – Fase Validación:

Cuadro N° 4.34: Estadísticos de la Fase de Validación de modelos de RNA con 4 - 3 variables comparados con el Método del Tanque clase A.

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
4	RNA - 46	f(HR, U2, Kp, E)	[4-8-1]	0.00370	0.4764	99.52	99.54	99.77
3	RNA - 47	f(HR, Vv, E)	[3-5-1]	0.00997	1.2817	98.71	98.78	99.39
	RNA - 49	f(Vv, Kp, E)	[3-8-1]	0.01547	1.9893	98.00	98.10	99.04
	RNA - 48	f(HR, Vv, Kp)	[3-5-1]	0.79178	101.8072	-2.43	1.09	10.43

Cuadro N° 4.35: Estadísticos de la Fase de Validación de modelos de RNA con 2 variables comparados con el Método del Tanque clase A.

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
2	RNA - 51	f(Vv, E)	[2-6-1]	0.02003	2.5757	97.41	97.63	98.81
	RNA - 50	f(HR, E)	[2-7-1]	0.02512	3.2299	96.75	96.81	98.39
	RNA - 52	f(HR, Vv)	[2-7-1]	0.79469	102.1818	-2.80	0.48	6.90

Cuadro N° 4.36: Estadísticos de la Fase de Validación de modelos de RNA con 1 variables comparados con el Método del Tanque clase A.

MODELOS DE RNA			ESTADÍSTICOS					
N°	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
1	RNA - 56	f(E)	[1-2-1]	0.03591	4.6177	95.35	95.50	97.72
	RNA - 55	f(Kp)	[1-4-1]	0.79144	101.7638	-2.38	1.07	10.36
	RNA - 54	f(Vv)	[1-7-1]	0.79363	102.0447	-2.67	0.81	8.98
	RNA - 53	f(HR)	[1-7-1]	0.79412	102.1085	-2.73	0.00	0.00

Grafico N° 4.15: Diagrama de dispersión modelo de RNA - 46 con 4 variables comparado con el Método del Tanque de Evaporación clase A – Fase de Validación.





Grafico N° 4.16: Diagrama de dispersión modelo de RNA - 47 con 3 variables comparado con el Método del Tanque de Evaporación clase A – Fase de Validación.



4.5. EVALUACIÓN Y SELECCIÓN DE MODELOS:

Después de realizar la validación, es importante comprobar la calidad del modelo resultante utilizando indicadores estadísticos como Error cuadrático medio (ECM), error cuadrático medio normalizado (ECMN), eficiencia de Nash y Sutcliffe (NSE), coeficiente de determinación (R^2), y el coeficiente de correlación (r). Los resultados de la evaluación se presentan en los cuadros N° 4.37, cuadros N° 4.38 y cuadros N° 4.39.

4.5.1. Selección de modelos con variables similares a FAO 56 Penman Monteith:

La selección de modelos de RNA con variables de entrada similares al método de FAO 56 Penman monteith son los modelos que se indican en el cuadro N° 4.37, de los cuales los modelos RNA-1, RNA-3, RNA-7, RNA-2, RNA-6, presentan un mejor desempeño con un porcentaje de ajuste igual a 95.97%, 90.75%, 89.67%, 89.48%, 87.02% respectivamente, así mismo sus coeficientes de correlación son 97.96%, 95.26%, 94.69%, 94.59%, 87.02% respectivamente.

Cuadro N° 4.37: Selección de modelos con variables similares a FAO 56 Penman Monteith – Fase Validación.

N°	MODELOS PLANTEADOS		ESTADÍSTICOS					
	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	r (%)	R2 (%)
1	RNA - 1	f(Tmin, Tmax, HR, Vv, HS)	[5-11-1]	0.09751	10.2399	89.72	97.96	95.97
2	RNA - 3	f(Tmin, HR, Vv, HS)	[4-2-1]	0.14011	14.7132	85.23	95.26	90.75
3	RNA - 7	f(Tmax, Vv, HS)	[3-8-1]	0.22103	23.2103	76.70	94.69	89.67
4	RNA - 2	f(Tmax, HR, Vv, HS)	[4-10-1]	0.21285	22.3509	77.57	94.59	89.48
5	RNA - 6	f(Tmin, Tmax, HR, Vv)	[4-4-1]	0.15568	16.3482	83.59	93.29	87.02
6	RNA - 12	f(Tmax, HR, VV)	[3-4-1]	0.18246	19.1606	80.77	92.10	84.82
7	RNA - 15	f(Tmin, Tmax, HR)	[3-5-1]	0.23078	24.2344	75.68	90.18	81.32
8	RNA - 20	f(Tmax, Vv)	[2-7-1]	0.31752	33.3432	66.53	88.32	78.00
9	RNA - 19	f(Tmax, HS)	[2-2-1]	0.32998	34.6514	65.22	88.27	77.91
10	RNA - 24	f(Tmin, HR)	[2-4-1]	0.30795	32.3381	67.54	87.74	76.99
11	RNA - 29	f(Tmax)	[1-5-1]	0.43992	46.1955	53.63	83.03	68.94

4.5.2. Selección de modelos con variables similares a Hargreaves - Samani (1985):

La selección de modelos de RNA con variables de entrada similares al método de Hargreaves –Samani (1985) son los modelos que se indican en el cuadro N° 4.38, de los cuales los modelos RNA-31, RNA-34, RNA-40, RNA-36, presentan un mejor desempeño con un porcentaje de ajuste igual a 99.73%, 99.67%, 96.22%, 80.33% respectivamente, así mismo sus coeficientes de correlación son 99.87%, 99.84%, 98.09% y 89.63% respectivamente.

Cuadro N° 4.38: Selección de modelos con variables similares a Hargreaves - Samani (1985) – Fase Validación.

N°	MODELOS PLANTEADOS		ESTADÍSTICOS					
	MODELOS	V. INDEPENDIENTES	ARQUITECTURA	ECM	ECMN (%)	NSE (%)	r (%)	R2 (%)
1	RNA - 31	f(Tmin,Tmax,Tmed, Ra)	[4-4-1]	0.00088	0.2768	99.72	99.87	99.73
2	RNA - 34	f(Tmin,Tmax,Ra)	[3-8-1]	0.00110	0.3462	99.65	99.84	99.67
3	RNA - 40	f(Tmax, Ra)	[2-7-1]	0.01912	6.0255	93.95	98.09	96.22
4	RNA - 36	f(Tmin,Tmax)	[2-5-1]	0.12814	40.3826	59.47	89.63	80.33
5	RNA - 43	f(Tmax)	[1-5-1]	0.17915	56.4557	43.34	82.53	68.11

4.5.3. Selección de modelos con variables similares al Tanque clase A:

La selección de modelos de RNA con variables de entrada similares al método del Tanque de Evaporación clase A son los modelos que se indican en el cuadro N° 4.39, de los cuales los modelos RNA-46, RNA-49, RNA-47, RNA-51 presentan un mejor desempeño con un porcentaje de ajuste igual a 99.73%, 99.72%, 99.42%, 98.65% respectivamente, así mismo sus coeficientes de correlación son 99.86%, 99.86%, 99.71% y 99.32% respectivamente.

Cuadro N° 4.39: Selección de modelos con variables similares al Tanque de Evaporación clase A – Fase Validación.

N°	MODELOS PLANTEADOS		INDICADORES ESTADÍSTICOS				
	MODELOS	VARIABLES	ECM	ECMN (%)	NSE (%)	r (%)	R2 (%)
1	RNA - 46	$ET_o = f(HR, U_2, K_p, E)$	0.00252	0.2771	99.72	99.86	99.73
2	RNA - 49	$ET_o = f(V_v, K_p, E)$	0.00274	0.3013	99.70	99.86	99.72
3	RNA - 47	$ET_o = f(HR, V_v, E)$	0.00590	0.6145	99.38	99.71	99.42
4	RNA - 51	$ET_o = f(V_v, E)$	0.01266	1.3941	98.60	98.32	98.65
5	RNA - 50	$ET_o = f(HR, E)$	0.04198	4.6215	95.36	97.66	95.37
6	RNA - 56	$ET_o = f(E)$	0.05211	5.7370	94.24	97.15	94.39

4.6. ESTIMACIÓN DE LA EVAPOTRANSPIRACIÓN DE REFERENCIA.

Para estimar la evapotranspiración de referencia utilizaremos un nuevo conjunto de datos de 365 días correspondientes al año 2013, por consiguientes se estimara la ET_o utilizando los modelos los modelos de RNA-1 y RNA-6 en función de elementos climáticos de la cuenca del río Huancané.

- ET_o para la estación Huancané para periodos de registro del año 2013.
- ET_o para la estación Putina para periodos de registro del año 2013.
- ET_o para la estación Muñani para periodos de registro del año 2013.

Los valores Estimados de la evapotranspiración de referencia ET_o utilizando modelos de RNA se muestran en el **ANEXO 4-3**

4.7. ANÁLISIS COMPARATIVO DE LA EVAPOTRANSPIRACIÓN DE REFERENCIA ESTIMADA CON RNA Y MÉTODOS EMPÍRICOS.

Para realizar el análisis comparativo de modelos primeramente se estimó la evapotranspiración de referencia (ET_o) utilizando el método de FAO 56 Penman Monteith y posteriormente se estimó la evapotranspiración de referencia (ET_o) utilizando los modelos RNA-1 y RNA-6 para la estación Huancané para el periodo de registro del año 2013.

Los resultados de los estadísticos se presentan en el cuadro N° 4.40, del cual los modelos RNA-1 y RNA-6 presentan un mejor desempeño con un porcentaje de ajuste igual a 93.13% y 83.64% respectivamente, así mismo sus coeficientes de correlación son 96.50% y 91.46% respectivamente.

ESTACIÓN HUANCANE

Cuadro N° 4.40: Comparación de estadísticos del modelo de RNA y método FAO 56 PM

N°	MODELOS PLANTEADOS		INDICADORES ESTADÍSTICOS				
	MODELOS	VARIABLES	ECM	ECMN (%)	NSE (%)	R2 (%)	r (%)
1	RNA - 1	ET _o = f(Tmin, Tmax, HR, Vv, HS)	0.06772	10.0345	89.94	93.13	96.50
2	RNA - 3	ET _o = f(Tmin, HR, Vv, HS)	0.09895	14.6620	85.30	86.73	93.13
3	RNA - 2	ET _o = f(Tmax, HR, Vv, HS)	0.18432	27.3114	72.61	84.40	91.87
4	RNA - 7	ET _o = f(Tmax, Vv, HS)	0.17380	25.7530	74.18	83.90	91.60
5	RNA - 6	ET _o = f(Tmin, Tmax, HR, Vv)	0.12114	17.9498	82.00	83.64	91.46
6	RNA - 12	ET _o = f(Tmax, HR, VV)	0.14488	21.4682	78.47	81.38	90.21
7	RNA - 19	ET _o = f(Tmax, HS)	0.21149	31.3373	68.58	75.75	87.04
8	RNA - 15	ET _o = f(Tmin, Tmax, HR)	0.18512	27.4310	72.49	75.19	86.71
9	RNA - 21	ET _o = f(Tmax, HR)	0.20828	30.8624	69.05	71.45	84.53
10	RNA - 9	ET _o = f(Tmin, HR, Vv)	0.20082	29.7574	70.16	71.03	84.28
11	RNA - 20	ET _o = f(Tmax, Vv)	0.24007	35.5723	64.33	70.53	83.98
12	RNA - 29	ET _o = f(Tmax)	0.30511	45.2105	54.67	62.91	79.31

Grafico N° 4.17: Diagrama de dispersión de ETo observada y RNA - 1 (Estación Huancané – año 2013).




Grafico N° 4.18: Diagrama de dispersión de ETo observada y RNA – 6 (Estación Huancané – año 2013).






Grafico N° 4.19: Comparación de modelos estimados con el método de FAO 56 P-M y modelos de RNA (Enero a Marzo - 2013)



Fuente: Elaboración propia

El grafico N° 4.19 muestra que para la estación Huancané para los meses de enero, febrero y marzo el modelo de RNA – 1 es el que mejor se ajusta a los datos observados con un coeficiente de correlación de $r=96.50\%$, así mismo se observa que el modelo de RNA – 6 con (4 variables) el que no considera la variable horas de sol (HS), muestra un excelente comportamiento en términos de las estadísticas con un coeficiente de correlación de $r=91.46\%$ para los 365 días del año 2013.

Grafico N° 4.20: Comparación de modelos estimados con el método de FAO 56 P-M y modelos de RNA (Octubre a Diciembre - 2013)




El grafico N° 4.20 muestra que para la estación Huancané para los meses de octubre, noviembre y diciembre el modelo de RNA – 1 es el que mejor se ajusta a los datos observados con un coeficiente de correlación de $r=96.50\%$, así mismo se observa que el modelo de RNA – 6 con (4 variables) el que no considera la variable horas de sol (HS), muestra un excelente comportamiento en términos de las estadísticas con un coeficiente de correlación de $r=91.46\%$ para los 365 días del año 2013.

COMPARACIÓN DE MODELOS EMPIRICOS

ESTACIÓN HUANCANÉ

Grafico N° 4.21: Comparación de modelos empíricos (Estación Huancané - Año 2010)




Fuente: Elaboración propia.

El grafico N° 4.21 muestra que el método de Hargreaves – Samani (1985) y el método del Tanque de Evaporación clase A subestiman la Evapotranspiración de referencia (ETo), por lo tanto el método FAO 56 es el método más indicado para estimar la ETo.

COMPARACIÓN DE MODELOS DE RNA CON EL MÉTODO HARGREAVES – SAMANI (1985)

ESTACIÓN MUÑANI

Grafico N° 4.22: Comparación de modelos de RNA - 6 (4 variables) con el método Hargreaves – Samani (1985) (Estación Muñani – Año 2013).



El grafico N° 4.22 muestra que el método de Hargreaves – Samani (1985) subestima la ETo, por lo tanto los resultados estimados por el modelo de RNA -6 con (4 variables) es el indicado para estimar la ETo con menos variables de entrada.

CAPITULO V

CONCLUSIONES

- ✓ Los resultados de la evapotranspiración de referencia utilizando modelos de Redes Neuronales Artificiales en función de elementos climáticos muestran un excelente comportamiento obteniendo un $R^2 = 93.13 \%$ para el modelo RNA-1 y $R^2 = 83.64 \%$ para el modelo RNA-6; por lo tanto se considera que esta metodología es muy eficiente en la estimación de la evapotranspiración de referencia.
- ✓ Mediante la presente investigación se ha logrado establecer 05 modelos de RNA que están en función de elementos climáticos, los cuales permiten pronosticar y estimar la evapotranspiración de referencia, estos modelos son: RNA-1 ($ET_o = T_{min}, T_{max}, HR, V_v, HS$); RNA-2 ($ET_o = T_{max}, HR, V_v, HS$); RNA-3 ($ET_o = T_{min}, HR, V_v, HS$); RNA-6 ($ET_o = T_{min}, T_{max}, HR, V_v$); RNA-7 ($ET_o = T_{max}, V_v, HS$).
- ✓ Se logro estimar la evapotranspiración de referencia para la estación Muñani utilizando el modelo RNA - 6 ($ET_o = T_{min}, T_{max}, HR, V_v$) el cual estimo valores similares a los que estima el método FAO 56 Penman Monteith por encima a lo que estima el método Hargreaves - Samani (1985) y el método del Tanque de evaporación clase A.
- ✓ Al realizar el análisis comparativo de la evapotranspiración de referencia estimada por modelos de RNA con los métodos empíricos, se observo que el modelos RNA -1 fue el modelo que mostro mejor desempeño frente a los métodos de Hargreaves - Samani (1985) y el método del Tanque de evaporación clase A.

RECOMENDACIONES

- ✓ Como resultado del presente trabajo de investigación se sugiere que la metodología propuesta de modelos de redes neuronales artificiales sea una metodología para estimar los valores de evapotranspiración de referencia.

- ✓ Se recomienda que en investigaciones futuras se realice otras investigaciones similares con modelos de redes neuronales artificiales.

- ✓ Finalmente se recomienda a las instituciones públicas, privadas y sectores involucrados en el manejo de la disponibilidad del recurso agua utilizar los modelos de redes neuronales artificiales para estimar la evapotranspiración de referencia.

BIBLIOGRAFÍA

- Alegre A. (2003). *“Simulación de redes neuronales artificiales: Una aplicación didáctica”*. Universidad Nacional del Nordeste. Argentina.
- Allen R., Pereira L., Raes D. and Smith M. (2006). *“Crop Evapotranspiration - Guidelines for computing crop water requirements – FAO irrigation and Drainage Paper 56”*. Food and Agriculture Organization of the United Nations. Rome. Italy.333p.
- Barría P. A. (2010). *“Pronóstico de caudales medios mensuales en las cuencas de los ríos Baker y Pascua”*. Universidad de Chile. Chile.
- Benites C. A. (2000). *“Sistemas Hidráulicos de Riego - Diseño y construcción”*. Arequipa. Editorial UNSA.
- Bertona L. F. (2005). *“Entrenamiento de Redes Neuronales Artificiales basado en algoritmos evolutivos”*. Universidad de Buenos Aires. Argentina.
- Bonilla M. (1997). *“Análisis de las Redes Neuronales: Aplicación a problemas de predicción y clasificación financiera”*. (Tesis de Maestría). Universidad de Valencia. España.
- Bravo J. M., Pilar J. V., Depettris C. A. (2004). *“Utilización de un modelos de redes neuronales en la obtención de la curva de descarga de la obra de control del rio negro en Laguna Blanca”*. Universidad Nacional del Nordeste. Argentina.
- Cabrera, J. (2008). *“Calibración de Modelos Hidrológicos”*. (Vol. 1).
- Caracheo F. (2002). *“Modelo Educativo”*. Dirección General de Institutos Tecnológicos. Coordinación Sectorial de Normatividad Académica. México: Ediciones CIDET.
- Catalán D. (2012). *“Modelización mediante redes neuronales del ensuciamiento de membranas cerámicas de ultrafiltración”*. (Tesis de Maestría). Universidad Politécnica de Valencia. España.
- Cervantes R. (2010). *“Redes neuronales artificiales para estimar y predecir variables climatológicas relacionadas con la evapotranspiración de referencia”*. (Tesis de Doctorado). Universidad autónoma Chapingo. México.
- Collantes J.V. (2001). *“Predicción con Redes Neuronales: comparación con las metodologías de Box y Jenkins”*. Universidad de los Andes. Mérida.Venezuela.

Doorenbos J. y Pruitt W. (1975). "*Guidelines for predicting crop water requirements*". Estudio FAO Riego y Drenaje N° 24. Organización de las Naciones Unidas para la Agricultura y la Alimentación. Roma. Italia.

Flores R. y Fernández J. M. (2008). "*Las Redes Neuronales Artificiales: Fundamentos teóricos y aplicaciones prácticas*". La Coruña. España.

Gurovich L. A. (1999). "*Riego superficial tecnificado*". Alfaomega, México. D.F. México.

Hernández L. (2006). "*Predicción y Optimización de emisores y consumo mediante Redes Neuronales en motores Diesel*". Barcelona. Editorial REVERTÉ.

Hilera J. R. y Martínez V. J. (1995). "*Redes Neuronales Artificiales: Fundamentos, modelos y aplicaciones*" Madrid: Ediciones RA-MA.

Ibañez V. (2009). "*Análisis y diseño de experimentos*". Universidad Nacional del Altiplano. Puno. Editorial Universitaria.

Laqui W. (2013). "*Estimación de la evapotranspiración de referencia ETo utilizando modelos de Redes Neuronales Artificiales en Llachahui*". II simposio internacional del lago Titicaca - TDP. ALT. Puno. Perú.

Lujano E. (2012). "*Pronostico de caudales medios mensuales del Río llave utilizando modelos de Redes Neuronales Artificiales*". Universidad Nacional del Altiplano. Puno. Perú.

Mateo J. (2012). "*Aplicación de Redes Neuronales Artificiales en el procesado versátil de señales eletrocardiográficas*". Universidad Politécnica de Valencia. España.

Narváez R. (2009). "*Redes neuronales artificiales y regresión de series temporales para la predicción de la cantidad demandada de Energía Eléctrica por empresas del sector Energético Eléctrico*". (Tesis de maestría). Universidad de Trujillo. Trujillo.

Pino R., Gomez A. y De abajo N. (2001). "*Introducción a la inteligencia artificial: sistemas expertos, redes neuronales artificiales y computación evolutiva*". Universidad de Oviedo.

Sifontes R.J. (2010). "*Estimación de demanda a mediano plazo de la subestación Lagunita utilizando Redes Neuronales*". Universidad Simón Bolívar. Sartenejas. Venezuela.

Steel R. y Torrie J. (1960). "*Principles and Procedures of Statistics with Special Reference to the Biological Sciences*". USA: McGraw-Hill. 242 p.

Tarjuelo J. M. (1999). *“El riego por aspersión y su tecnología”*. Madrid: Ediciones Mundi - Prensa.

Thornthwaite C.W. (1948). *“An Approach Toward a Rational Classification of Climate”*. Geography Review. Vol. 38.

Torra S. y Monte E. (2013). *“Modelos Neuronales aplicados en Economía: casos prácticos mediante mathematica / Neuronal Networks”*. Barcelona. España.

Vásquez A. (1984). *“Principios básicos del riego”*. Universidad Agraria la Molina. Facultad de Ingeniería Agrícola. Lima: Ediciones FIMART.

Vidaurre Y. A. (2012). *“Aplicación de las Redes Neuronales Artificiales para el pronóstico de la demanda de agua potable en la empresa EPSEL S.A de la ciudad de Lambayeque”*. Universidad católica Santo Toribio de Mogrovejo. Lambayeque. Perú.

ANEXOS

ANEXO 2

ANEXO N° 2.1: Insolación máxima diaria (N) para diferentes latitudes.

Lat. grad.	Hemisferio Norte											
	Ene.	Feb.	Marzo	Abril	Mayo	Junio	Julio	Ago.	Sep.	Oct.	Nov.	Dic.
0,0	6,6	11,0	15,6	21,3	24,0	24,0	24,0	17,6	12,8	8,3	2,3	0,0
1,1	7,3	11,1	15,3	19,7	22,3	22,3	22,3	17,0	12,7	8,7	4,1	0,0
3,9	7,8	11,2	14,9	18,7	22,0	20,3	16,4	12,7	9,0	5,2	1,9	0,0
5,0	8,2	11,2	14,7	17,9	20,3	19,2	16,0	12,6	9,3	6,0	3,7	0,0
5,7	8,5	11,3	14,4	17,3	19,2	18,4	15,7	12,6	9,5	6,6	4,8	0,0
6,4	8,8	11,4	14,2	16,8	18,4	17,7	15,3	12,5	9,7	7,1	5,6	0,0
6,9	9,1	11,4	14,1	16,4	17,8	17,2	15,1	12,5	9,9	7,5	6,2	0,0
7,3	9,3	11,5	13,9	16,0	17,3	16,8	14,8	12,4	10,1	7,9	6,7	0,0
7,7	9,5	11,5	13,8	15,7	16,8	16,4	14,6	12,4	10,2	8,2	7,1	0,0
8,0	9,7	11,5	13,6	15,4	16,5	16,0	14,4	12,4	10,3	8,5	7,5	0,0
8,3	9,8	11,6	13,5	15,2	16,1	15,7	14,3	12,3	10,4	8,7	7,9	0,0
8,6	10,0	11,6	13,4	15,0	15,8	15,5	14,1	12,3	10,6	9,0	8,2	0,0
8,8	10,1	11,6	13,3	14,8	15,5	15,2	14,0	12,3	10,7	9,2	8,5	0,0
9,1	10,3	11,6	13,2	14,6	15,3	15,0	13,8	12,3	10,7	9,4	8,7	0,0
9,3	10,4	11,7	13,2	14,4	15,0	14,8	13,7	12,3	10,8	9,6	9,0	0,0
9,5	10,5	11,7	13,1	14,2	14,8	14,6	13,6	12,2	10,9	9,7	9,2	0,0
9,6	10,6	11,7	13,0	14,1	14,6	14,4	13,5	12,2	11,0	9,9	9,4	0,0
9,8	10,7	11,7	12,9	13,9	14,4	14,2	13,4	12,2	11,1	10,1	9,6	0,0
10,0	10,8	11,8	12,9	13,8	14,3	14,1	13,3	12,2	11,1	10,2	9,7	0,0
10,1	10,9	11,8	12,8	13,6	14,1	13,9	13,2	12,2	11,2	10,3	9,9	0,0
10,3	11,0	11,8	12,7	13,5	13,9	13,8	13,1	12,2	11,3	10,5	10,1	0,0
10,4	11,0	11,8	12,7	13,4	13,8	13,6	13,0	12,2	11,3	10,6	10,2	0,0
10,5	11,1	11,8	12,6	13,3	13,6	13,5	12,9	12,1	11,4	10,7	10,4	0,0
10,7	11,2	11,8	12,6	13,2	13,5	13,3	12,8	12,1	11,4	10,8	10,5	0,0
10,8	11,3	11,9	12,5	13,1	13,3	13,2	12,8	12,1	11,5	10,9	10,7	0,0
10,9	11,3	11,9	12,5	12,9	13,2	13,1	12,7	12,1	11,5	11,0	10,8	0,0
11,0	11,4	11,9	12,4	12,8	13,1	13,0	12,6	12,1	11,6	11,1	10,9	0,0
11,1	11,5	11,9	12,4	12,7	12,9	12,9	12,5	12,1	11,6	11,2	11,1	0,0
11,3	11,6	11,9	12,3	12,6	12,8	12,8	12,5	12,1	11,7	11,3	11,2	0,0
11,4	11,6	11,9	12,3	12,6	12,7	12,6	12,4	12,1	11,7	11,4	11,3	0,0
11,5	11,7	11,9	12,2	12,5	12,6	12,5	12,3	12,1	11,8	11,5	11,4	0,0
11,6	11,7	11,9	12,2	12,4	12,5	12,4	12,3	12,0	11,8	11,6	11,5	0,0
11,7	11,8	12,0	12,1	12,3	12,3	12,3	12,2	12,0	11,9	11,7	11,7	0,0
11,8	11,9	12,0	12,1	12,2	12,2	12,2	12,1	12,0	11,9	11,8	11,8	0,0
11,9	11,9	12,0	12,0	12,1	12,1	12,1	12,1	12,0	12,0	11,9	11,9	0,0
12,0	12,0	12,0	12,0	12,0	12,0	12,0	12,0	12,0	12,0	12,0	12,0	0,0

Lat. grad.	Hemisferio Sur											
	Ene.	Feb.	Marzo	Abril	Mayo	Junio	Julio	Ago.	Sep.	Oct.	Nov.	Dic.
70	24,0	17,4	13,0	8,4	2,7	0,0	0,0	6,4	11,2	15,7	21,7	24,0
68	21,9	16,7	12,9	8,7	4,3	0,0	1,7	7,0	11,3	15,3	19,9	24,0
66	20,1	16,2	12,8	9,1	5,3	2,0	3,7	7,6	11,3	15,0	18,8	22,1
64	19,0	15,8	12,8	9,3	6,1	3,7	4,8	8,0	11,4	14,7	18,0	20,3
62	18,3	15,5	12,7	9,6	6,7	4,8	5,6	8,3	11,4	14,5	17,4	19,2
60	17,6	15,2	12,6	9,8	7,2	5,6	6,3	8,7	11,5	14,3	16,9	18,4
58	17,1	14,9	12,6	9,9	7,6	6,2	6,8	8,9	11,5	14,1	16,5	17,8
56	16,7	14,7	12,5	10,1	8,0	6,7	7,2	9,2	11,6	13,9	16,1	17,3
54	16,3	14,5	12,5	10,2	8,3	7,2	7,6	9,4	11,6	13,8	15,8	16,9
52	16,0	14,3	12,5	10,4	8,6	7,5	8,0	9,6	11,6	13,7	15,5	16,5
50	15,7	14,2	12,4	10,5	8,8	7,9	8,3	9,7	11,7	13,6	15,3	16,1
48	15,4	14,0	12,4	10,6	9,0	8,2	8,5	9,9	11,7	13,4	15,0	15,8
46	15,2	13,9	12,4	10,7	9,2	8,5	8,8	10,0	11,7	13,3	14,8	15,5
44	14,9	13,7	12,4	10,8	9,4	8,7	9,0	10,2	11,7	13,3	14,6	15,3
42	14,7	13,6	12,3	10,8	9,6	9,0	9,2	10,3	11,7	13,2	14,4	15,0
40	14,5	13,5	12,3	10,9	9,8	9,2	9,4	10,4	11,8	13,1	14,3	14,8
38	14,4	13,4	12,3	11,0	9,9	9,4	9,6	10,5	11,8	13,0	14,1	14,6
36	14,2	13,3	12,3	11,1	10,1	9,6	9,8	10,6	11,8	12,9	13,9	14,4
34	14,0	13,2	12,2	11,1	10,2	9,7	9,9	10,7	11,8	12,9	13,8	14,3
32	13,9	13,1	12,2	11,2	10,4	9,9	10,1	10,8	11,8	12,8	13,7	14,1
30	13,7	13,0	12,2	11,3	10,5	10,1	10,2	10,9	11,8	12,7	13,5	13,9
28	13,6	13,0	12,2	11,3	10,6	10,2	10,4	11,0	11,8	12,7	13,4	13,8
26	13,5	12,9	12,2	11,4	10,7	10,4	10,5	11,1	11,9	12,6	13,3	13,6
24	13,3	12,8	12,2	11,4	10,8	10,5	10,7	11,2	11,9	12,6	13,2	13,5
22	13,2	12,7	12,1	11,5	10,9	10,7	10,8	11,2	11,9	12,5	13,1	13,3
20	13,1	12,7	12,1	11,5	11,1	10,8	10,9	11,3	11,9	12,5	13,0	13,2
18	13,0	12,6	12,1	11,6	11,2	10,9	11,0	11,4	11,9	12,4	12,9	13,1
16	12,9	12,5	12,1	11,6	11,3	11,1	11,1	11,5	11,9	12,4	12,8	12,9
14	12,7	12,4	12,1	11,7	11,4	11,2	11,2	11,5	11,9	12,3	12,7	12,8
12	12,6	12,4	12,1	11,7	11,4	11,3	11,4	11,6	11,9	12,3	12,6	12,7
10	12,5	12,3	12,1	11,8	11,5	11,4	11,5	11,7	11,9	12,2	12,5	12,6
8	12,4	12,3	12,1	11,8	11,6	11,5	11,6	11,7	12,0	12,2	12,4	12,5
6	12,3	12,2	12,0	11,9	11,7	11,7	11,7	11,8	12,0	12,1	12,3	12,3
4	12,2	12,1	12,0	11,9	11,8	11,8	11,8	11,9	12,0	12,1	12,2	12,2
2	12,1	12,1	12,0	12,0	11,9	11,9	11,9	12,0	12,0	12,0	12,1	12,1
0	12,0	12,0	12,0	12,0	12,0	12,0	12,0	12,0	12,0	12,0	12,0	12,0

ANEXO N° 2.2: Número de día en el año (J)

CUADRO A2.5 (continuación)
Número de día en el año (J)

Día	Julio*	Agosto*	Septiembre*	Octubre*	Noviembre*	Diciembre*
1	182	213	244	274	305	335
2	183	214	245	275	306	336
3	184	215	246	276	307	337
4	185	216	247	277	308	338
5	186	217	248	278	309	339
6	187	218	249	279	310	340
7	188	219	250	280	311	341
8	189	220	251	281	312	342
9	190	221	252	282	313	343
10	191	222	253	283	314	344
11	192	223	254	284	315	345
12	193	224	255	285	316	346
13	194	225	256	286	317	347
14	195	226	257	287	318	348
15	196	227	258	288	319	349
16	197	228	259	289	320	350
17	198	229	260	290	321	351
18	199	230	261	291	322	352
19	200	231	262	292	323	353
20	201	232	263	293	324	354
21	202	233	264	294	325	355
22	203	234	265	295	326	356
23	204	235	266	296	327	357
24	205	236	267	297	328	358
25	206	237	268	298	329	359
26	207	238	269	299	330	360
27	208	239	270	300	331	361
28	209	240	271	301	332	362
29	210	241	272	302	333	363
30	211	242	273	303	334	364
31	212	243	-	304	-	365

* anadir 1 en caso de año bisiesto

CUADRO A2.5

Número de día en el año (J)

Día	Enero	Febrero	Marzo*	Abril*	Mayo*	Junio*
1	1	32	60	91	121	152
2	2	33	61	92	122	153
3	3	34	62	93	123	154
4	4	35	63	94	124	155
5	5	36	64	95	125	156
6	6	37	65	96	126	157
7	7	38	66	97	127	158
8	8	39	67	98	128	159
9	9	40	68	99	129	160
10	10	41	69	100	130	161
11	11	42	70	101	131	162
12	12	43	71	102	132	163
13	13	44	72	103	133	164
14	14	45	73	104	134	165
15	15	46	74	105	135	166
16	16	47	75	106	136	167
17	17	48	76	107	137	168
18	18	49	77	108	138	169
19	19	50	78	109	139	170
20	20	51	79	110	140	171
21	21	52	80	111	141	172
22	22	53	81	112	142	173
23	23	54	82	113	143	174
24	24	55	83	114	144	175
25	25	56	84	115	145	176
26	26	57	85	116	146	177
27	27	58	86	117	147	178
28	28	59	87	118	148	179
29	29	(60)	88	119	149	180
30	30	-	89	120	150	181
31	31	-	90	-	151	-

* anadir 1 en caso de año bisiesto

ANEXO N° 2.3: Factores de conversión para convertir la velocidad del viento

$$\text{factor de conversión} = u_z \frac{4,87}{\ln(67,8 z - 5,42)} \quad (\text{Ec. 47})$$

z altura (m)	Factor de conversión	z altura (m)	Factor de conversión	z altura (m)	Factor de conversión	z altura (m)	Factor de conversión
-	-	2,2	0,980	4,2	0,865	6,0	0,812
-	-	2,4	0,963	4,4	0,857	6,5	0,802
-	-	2,6	0,947	4,6	0,851	7,0	0,792
-	-	2,8	0,933	4,8	0,844	7,5	0,783
1,0	1,178	3,0	0,921	5,0	0,838	8,0	0,775
1,2	1,125	3,2	0,910	5,2	0,833	8,5	0,767
1,4	1,084	3,4	0,899	5,4	0,827	9,0	0,760
1,6	1,051	3,6	0,889	5,6	0,822	9,5	0,754
1,8	1,023	3,8	0,881	5,8	0,817	10,0	0,748
2,0	1,000	4,0	0,872	6,0	0,812	10,5	0,742

ANEXO N° 2.4: Presión de vapor de saturación para diferentes temperaturas

$$e^{\circ}(T) = 0,6108 * \exp\left[\frac{17,27 * T}{T + 237,3}\right] \quad (\text{Ec.11})$$

T °C	e°(T) kPa	T °C	e°(T) kPa	T °C	e°(T) kPa	T °C	e°(T) kPa
1,0	0,657	13,0	1,498	25,0	3,168	37,0	6,275
1,5	0,681	13,5	1,547	25,5	3,263	37,5	6,448
2,0	0,706	14,0	1,599	26,0	3,361	38,0	6,625
2,5	0,731	14,5	1,651	26,5	3,462	38,5	6,806
3,0	0,758	15,0	1,705	27,0	3,565	39,0	6,991
3,5	0,785	15,5	1,761	27,5	3,671	39,5	7,181
4,0	0,813	16,0	1,818	28,0	3,780	40,0	7,376
4,5	0,842	16,5	1,877	28,5	3,891	40,5	7,574
5,0	0,872	17,0	1,938	29,0	4,006	41,0	7,778
5,5	0,903	17,5	2,000	29,5	4,123	41,5	7,986
6,0	0,935	18,0	2,064	30,0	4,243	42,0	8,199
6,5	0,968	18,5	2,130	30,5	4,366	42,5	8,417
7,0	1,002	19,0	2,197	31,0	4,493	43,0	8,640
7,5	1,037	19,5	2,267	31,5	4,622	43,5	8,867
8,0	1,073	20,0	2,338	32,0	4,755	44,0	9,101
8,5	1,110	20,5	2,412	32,5	4,891	44,5	9,339
9,0	1,148	21,0	2,487	33,0	5,030	45,0	9,582
9,5	1,187	21,5	2,564	33,5	5,173	45,5	9,832
10,0	1,228	22,0	2,644	34,0	5,319	46,0	10,086
10,5	1,270	22,5	2,726	34,5	5,469	46,5	10,347
11,0	1,313	23,0	2,809	35,0	5,623	47,0	10,613
11,5	1,357	23,5	2,896	35,5	5,780	47,5	10,885
12,0	1,403	24,0	2,984	36,0	5,941	48,0	11,163
12,5	1,449	24,5	3,075	36,5	6,106	48,5	11,447

ANEXO Nº 2.5: Pendiente de la curva de presión de vapor (Δ)

$$\Delta = \frac{4098 * \left[0,6108 * \exp\left(\frac{17,27 * T}{T + 237,3}\right) \right]}{(T + 237,3)^2} \quad \text{(Ec. 13)}$$

T °C	Δ kPa/°C	T °C	Δ kPa/°C	T °C	Δ kPa/°C	T °C	Δ kPa/°C
1,0	0,047	13,0	0,098	25,0	0,189	37,0	0,342
1,5	0,049	13,5	0,101	25,5	0,194	37,5	0,350
2,0	0,050	14,0	0,104	26,0	0,199	38,0	0,358
2,5	0,052	14,5	0,107	26,5	0,204	38,5	0,367
3,0	0,054	15,0	0,110	27,0	0,209	39,0	0,375
3,5	0,055	15,5	0,113	27,5	0,215	39,5	0,384
4,0	0,057	16,0	0,116	28,0	0,220	40,0	0,393
4,5	0,059	16,5	0,119	28,5	0,226	40,5	0,402
5,0	0,061	17,0	0,123	29,0	0,231	41,0	0,412
5,5	0,063	17,5	0,126	29,5	0,237	41,5	0,421
6,0	0,065	18,0	0,130	30,0	0,243	42,0	0,431
6,5	0,067	18,5	0,133	30,5	0,249	42,5	0,441
7,0	0,069	19,0	0,137	31,0	0,256	43,0	0,451
7,5	0,071	19,5	0,141	31,5	0,262	43,5	0,461
8,0	0,073	20,0	0,145	32,0	0,269	44,0	0,471
8,5	0,075	20,5	0,149	32,5	0,275	44,5	0,482
9,0	0,078	21,0	0,153	33,0	0,282	45,0	0,493
9,5	0,080	21,5	0,157	33,5	0,289	45,5	0,504
10,0	0,082	22,0	0,161	34,0	0,296	46,0	0,515
10,5	0,085	22,5	0,165	34,5	0,303	46,5	0,526
11,0	0,087	23,0	0,170	35,0	0,311	47,0	0,538
11,5	0,090	23,5	0,174	35,5	0,318	47,5	0,550
12,0	0,092	24,0	0,179	36,0	0,326	48,0	0,562
12,5	0,095	24,5	0,184	36,5	0,334	48,5	0,574

ANEXO Nº 2.6: Constante psicrométrica (γ) para diferentes alturas

$$\gamma = \frac{c_p P}{\epsilon \lambda} = 0,665 * 10^{-3} \quad \text{(Ec. 8)}$$

z (m)	γ kPa/°C	z (m)	γ kPa/°C	z (m)	γ kPa/°C	z (m)	γ kPa/°C
0	0,067	1 000	0,060	2 000	0,053	3 000	0,047
100	0,067	1 100	0,059	2 100	0,052	3 100	0,046
200	0,066	1 200	0,058	2 200	0,052	3 200	0,046
300	0,065	1 300	0,058	2 300	0,051	3 300	0,045
400	0,064	1 400	0,057	2 400	0,051	3 400	0,045
500	0,064	1 500	0,056	2 500	0,050	3 500	0,044
600	0,063	1 600	0,056	2 600	0,049	3 600	0,043
700	0,062	1 700	0,055	2 700	0,049	3 700	0,043
800	0,061	1 800	0,054	2 800	0,048	3 800	0,042
900	0,061	1 900	0,054	2 900	0,047	3 900	0,042
1 000	0,060	2 000	0,053	3 000	0,047	4 000	0,041

ANEXO 4

ANEXO 4.1

ESTIMACIÓN DE LA EVAPOTRANSPIRACIÓN DE REFERENCIA

Métodos empíricos para la estación Huancané:

- Método de FAO 56 Penman - Monteith
- Método Hargreaves – Samani (1985)
- Método del tanque de evaporación clase A

Métodos empíricos para la estación Putina:

- Método de FAO 56 Penman - Monteith
- Método Hargreaves – Samani (1985)
- Método del tanque de evaporación clase A


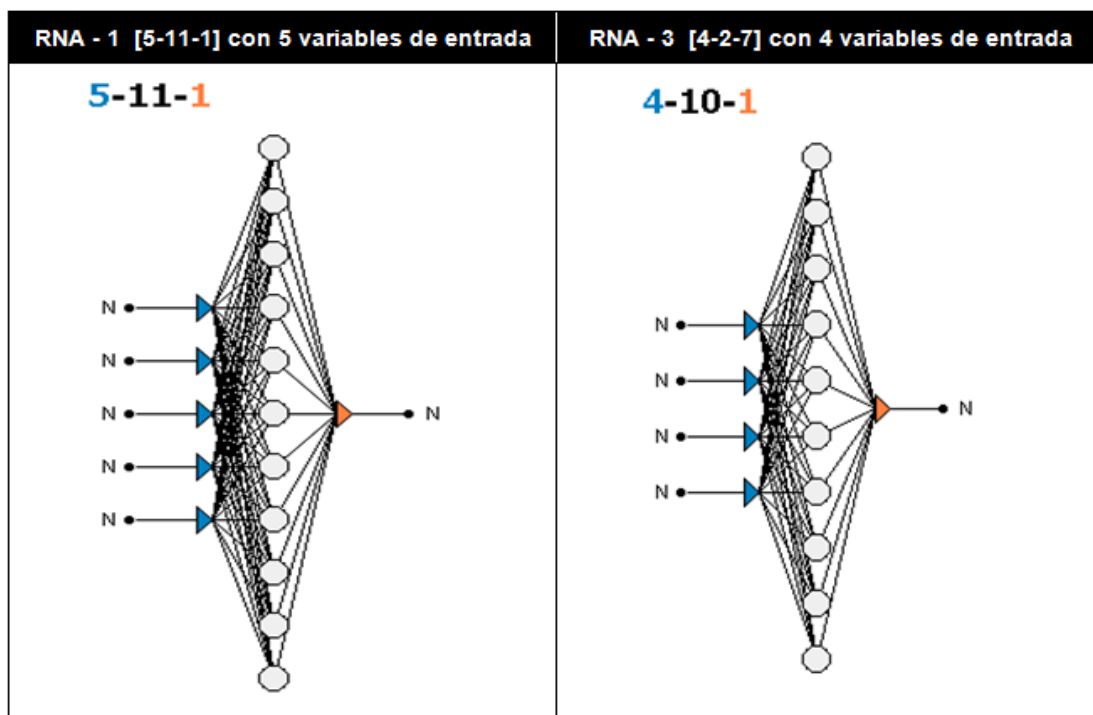
Métodos empíricos para la estación Muñani:

- Método Hargreaves – Samani (1985)
- Método del tanque de evaporación clase A

ANEXO 4.2

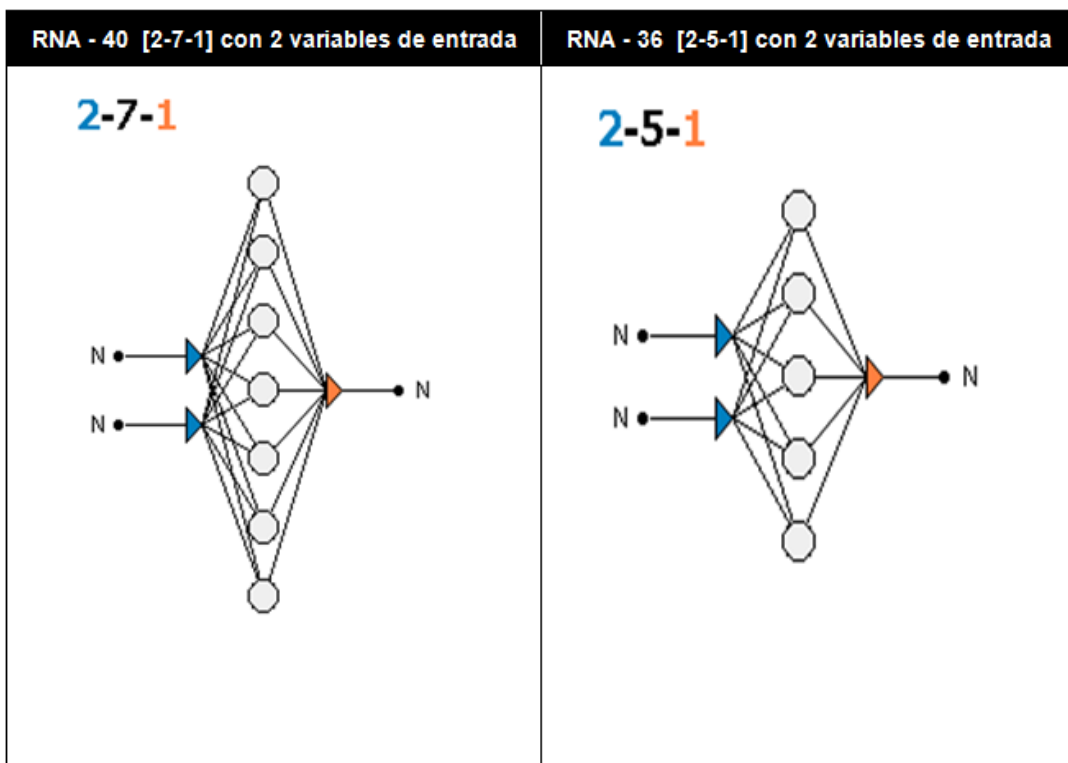
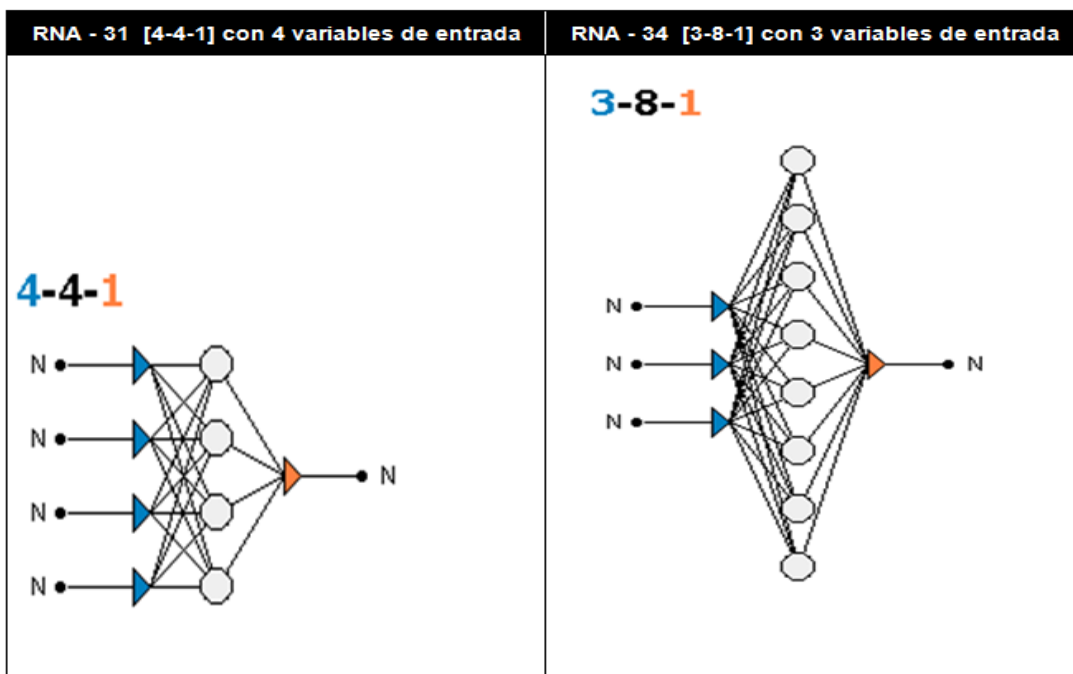
ARQUITECTURA SIMPLIFICADA DE LOS MODELOS DE REDES NEURONALES ARTIFICIALES

ANEXO 4.2. Arquitectura simplificada de modelos de RNA con variables similares al método FAO 56 Penman Monteith



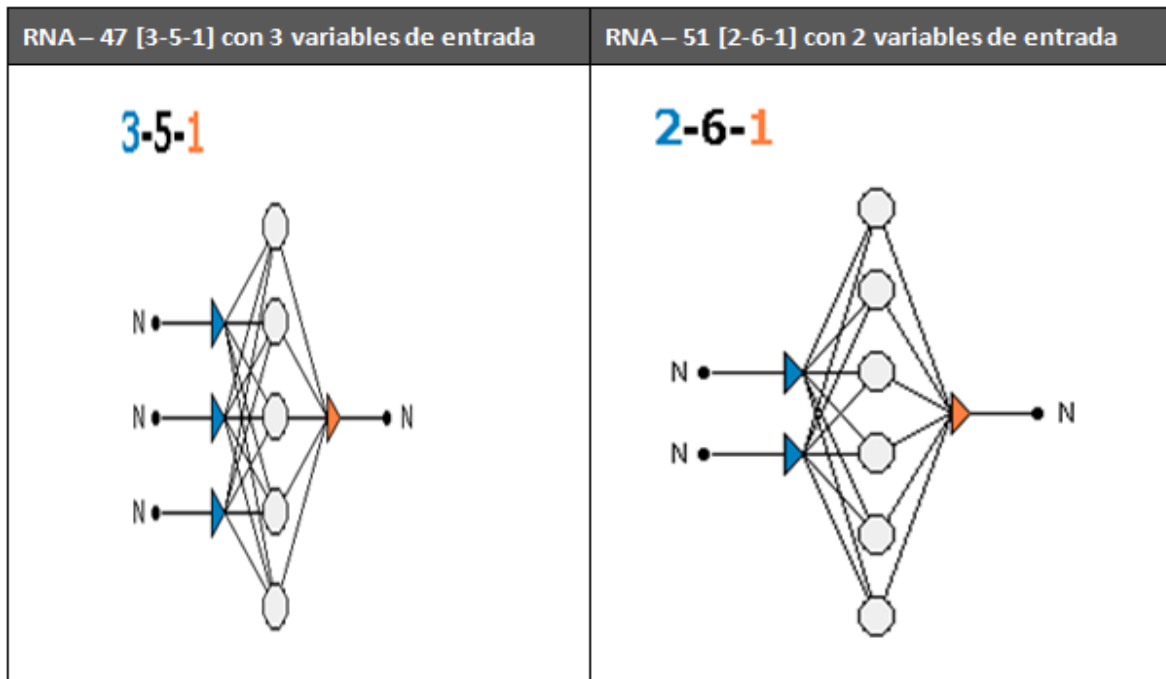
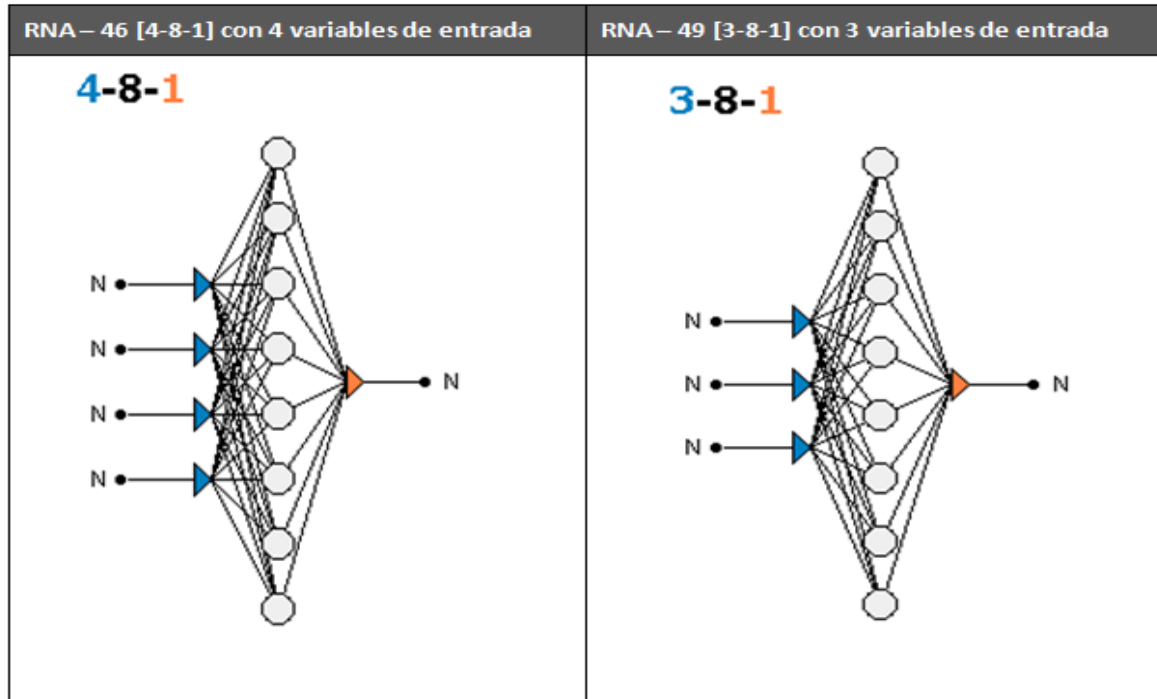
Fuente: [Aldyuda neurointelligence versión 2.2](#)

ANEXO 4.2. Arquitectura simplificada de modelos de RNA con variables similares al método Hargreaves - Samani (1985).



Fuente: [Aldyuda neurointelligence](#) versión 2.2

ANEXO 4.2. Arquitectura simplificada de modelos de RNA con variables similares al método del Tanque de Evaporación de clase A



Fuente: Aldyuda neurointelligence versión 2.2

ANEXO 4.3

ESTIMACIÓN DE LA EVAPOTRANSPIRACION DE REFERENCIA CON MODELOS DE REDES NEURONALES

EVAPOTRNSPIRACIÓN DE REFERENCIA (ET_o) ESTIMADO CON RNA - 1

ESTACIÓN HUANCANÉ - (año 2013)

DIA	MESES											
	ENE.	FEB.	MAR.	ABR.	MAY.	JUN.	JUL.	AGO.	SET.	OCT.	NOV.	DIC.
1	3.00	3.35	3.24	3.84	3.19	2.93	2.83	3.07	4.32	4.25	3.71	4.90
2	2.40	2.75	3.16	3.15	3.17	2.82	2.51	4.07	3.66	4.12	3.45	5.23
3	2.97	2.15	3.83	3.94	2.76	2.98	3.45	3.39	3.37	4.90	2.50	5.21
4	3.57	3.19	3.42	3.19	3.08	2.90	2.81	2.82	3.34	4.71	3.11	2.60
5	2.41	2.60	3.58	2.95	3.05	2.96	2.39	3.68	3.76	4.03	3.55	3.34
6	2.18	2.61	3.35	3.32	3.55	2.10	2.90	4.00	4.25	4.13	3.55	3.16
7	3.30	3.00	2.55	3.05	3.58	2.50	3.33	3.22	3.81	4.08	5.03	2.88
8	2.62	3.13	2.64	3.82	3.25	2.84	3.07	2.71	4.28	4.13	5.57	3.21
9	2.54	2.94	3.28	3.72	3.72	3.13	2.91	3.90	4.26	3.67	5.07	2.41
10	2.90	3.15	3.45	3.68	3.50	2.75	2.90	3.03	3.28	3.73	5.39	2.82
11	2.40	2.86	3.29	3.02	3.22	2.52	3.15	2.77	4.48	4.55	5.23	2.19
12	2.31	3.44	3.35	4.46	3.67	2.32	3.11	2.91	4.16	4.73	4.43	2.25
13	2.39	3.04	3.46	3.32	2.95	2.44	2.62	3.11	5.22	2.33	4.42	2.48
14	3.06	2.65	3.12	3.06	3.37	3.55	2.47	3.32	3.58	2.31	4.13	2.80
15	3.40	2.24	2.46	3.50	2.95	2.71	2.42	3.82	4.43	2.45	4.55	2.52
16	2.42	2.87	2.88	3.66	2.52	2.82	2.75	3.49	5.22	3.79	5.04	2.74
17	2.41	2.70	2.89	3.44	2.38	2.80	2.81	4.12	4.20	5.19	4.52	3.44
18	2.41	3.07	3.21	3.14	2.49	2.70	2.65	3.40	5.10	5.27	5.69	4.30
19	2.74	3.20	3.70	2.60	2.75	2.87	2.58	3.56	5.07	4.81	5.53	3.72
20	3.17	2.50	3.41	3.10	3.23	3.63	3.11	3.67	3.40	5.34	3.99	2.67
21	3.17	2.61	3.37	3.13	3.42	3.17	3.10	4.13	4.20	5.34	2.48	2.52
22	2.77	2.85	3.36	3.75	3.47	2.52	4.29	4.00	5.20	3.86	2.41	3.13
23	2.99	3.07	3.83	3.39	3.48	2.65	3.48	3.15	4.60	5.13	3.56	2.73
24	2.88	3.52	4.25	3.42	3.33	2.55	2.85	2.13	4.63	2.51	4.42	2.77
25	3.84	3.26	3.00	3.51	3.23	3.94	3.22	2.32	4.52	3.03	4.87	3.13
26	3.26	3.05	3.66	3.14	3.48	2.96	3.09	3.54	4.86	2.35	4.60	3.47
27	3.52	3.16	3.30	3.46	3.19	2.65	3.16	2.73	4.64	2.70	4.97	2.61
28	3.29	2.33	2.61	3.84	2.75	2.75	3.75	2.03	4.19	2.22	4.12	2.48
29	3.15		3.05	3.69	2.93	2.46	3.01	2.78	4.38	3.61	5.35	3.40
30	2.77		3.61	3.41	2.74	2.70	2.91	3.17	4.01	4.12	4.68	2.77
31	3.66		3.54		3.01		3.60	3.67		3.35		2.72
Promedio	2.9	2.9	3.3	3.4	3.1	2.8	3.0	3.3	4.3	3.9	4.3	3.1
Nº Datos	31	28	31	30	31	30	31	31	30	31	30	31
Desv. Est	0.5	0.4	0.4	0.4	0.4	0.4	0.4	0.6	0.6	1.0	0.9	0.8
Min	2.2	2.2	2.5	2.6	2.4	2.1	2.4	2.0	3.3	2.2	2.4	2.2
Max	3.8	3.5	4.3	4.5	3.7	3.9	4.3	4.1	5.2	5.3	5.7	5.2

EVAPOTRNSPIRACIÓN DE REFERENCIA (ET_o) ESTIMADO CON RNA - 6

ESTACIÓN HUANCANÉ - (año 2013)

DIA	MESES											
	ENE.	FEB.	MAR.	ABR.	MAY.	JUN.	JUL.	AGO.	SET.	OCT.	NOV.	DIC.
1	3.06	3.14	3.11	3.67	3.34	3.02	2.88	3.22	4.13	4.56	3.45	4.95
2	2.84	2.66	3.22	3.46	3.32	3.22	2.64	4.30	3.41	3.93	3.49	5.24
3	3.08	2.21	3.40	4.17	2.90	3.12	3.78	3.59	3.23	4.76	2.62	5.13
4	3.81	3.24	3.29	3.18	3.67	2.97	3.10	2.71	3.57	4.89	3.14	2.88
5	2.38	2.74	3.30	3.13	3.09	3.11	2.75	3.78	3.58	4.47	3.34	3.69
6	2.37	2.88	3.36	3.42	3.41	2.34	2.99	4.21	4.13	4.31	3.06	3.28
7	3.13	2.68	2.50	3.34	3.63	2.65	3.43	3.47	3.56	4.49	4.66	3.21
8	2.92	2.98	2.98	3.62	3.32	2.85	3.06	3.11	4.18	4.54	5.14	3.15
9	2.68	2.75	3.02	3.70	3.83	3.36	3.07	4.14	4.04	4.17	4.89	2.77
10	2.84	2.85	3.12	3.88	3.52	2.57	2.77	3.27	2.97	3.82	5.32	3.18
11	2.64	2.71	3.25	3.34	3.49	2.73	3.26	2.65	4.48	4.47	4.80	2.47
12	2.67	2.98	3.33	4.55	4.00	2.37	3.21	2.94	3.98	4.46	4.37	2.62
13	2.38	2.93	3.63	3.49	3.58	2.39	2.79	3.09	5.04	2.35	4.35	2.90
14	2.90	2.44	3.45	3.66	3.57	3.84	2.39	3.35	3.59	2.22	4.12	3.53
15	3.10	2.30	2.62	3.64	3.11	2.79	2.28	4.00	4.45	2.67	4.83	2.71
16	2.66	3.16	3.03	3.70	2.28	2.85	2.57	3.49	5.23	3.72	4.73	2.80
17	2.69	2.99	2.82	3.52	2.53	3.09	2.68	4.19	3.76	4.74	4.75	3.17
18	2.67	2.96	3.02	2.97	3.10	3.00	2.77	3.43	5.18	5.21	5.48	3.54
19	3.07	3.08	3.64	2.81	2.41	3.65	2.47	3.62	5.27	4.76	5.40	3.36
20	3.08	2.55	3.20	2.71	3.08	3.83	2.93	3.76	3.57	4.91	3.75	3.05
21	2.82	2.56	3.40	3.18	3.53	3.37	3.40	4.14	4.54	5.39	2.65	2.79
22	2.88	3.02	3.65	3.79	3.70	2.92	4.41	4.11	4.99	4.42	2.67	2.81
23	3.12	2.98	3.54	3.22	3.78	3.26	3.78	3.79	4.65	5.19	3.02	2.91
24	2.84	3.41	4.08	3.26	3.72	3.05	2.69	2.03	4.76	2.79	3.97	2.77
25	3.81	3.51	3.46	3.42	3.15	4.16	3.25	2.51	4.62	3.58	4.31	2.67
26	3.13	2.94	3.22	3.04	3.49	3.16	3.02	3.49	4.54	2.65	4.61	3.17
27	3.21	2.99	2.82	3.41	3.28	2.75	3.35	3.08	4.92	2.83	4.27	2.93
28	3.28	2.59	2.71	3.86	2.98	2.88	3.88	2.11	4.60	2.56	4.10	2.54
29	2.77		3.07	3.55	3.20	2.46	3.15	2.85	4.51	3.04	5.45	3.68
30	2.82		3.39	3.45	2.78	2.80	2.93	3.02	3.74	3.95	4.58	3.11
31	3.19		3.38		3.22		3.82	3.87		3.20		2.99
Promedio	2.9	2.9	3.2	3.5	3.3	3.0	3.1	3.4	4.2	4.0	4.2	3.2
Nº Datos	31	28	31	30	31	30	31	31	30	31	30	31
Desv. Est	0.3	0.3	0.3	0.4	0.4	0.4	0.5	0.6	0.6	0.9	0.9	0.7
Min	2.4	2.2	2.5	2.7	2.3	2.3	2.3	2.0	3.0	2.2	2.6	2.5
Max	3.8	3.5	4.1	4.6	4.0	4.2	4.4	4.3	5.3	5.4	5.5	5.2

EVAPOTRNSPIRACIÓN DE REFERENCIA (ET_o) ESTIMADO CON RNA - 1**ESTACIÓN PUTINA - (año 2013)**

DIA	MESES											
	ENE.	FEB.	MAR.	ABR.	MAY.	JUN.	JUL.	AGO.	SET.	OCT.	NOV.	DIC.
1	3.18	3.38	3.58	3.97	2.48	2.69	2.89	3.17	3.80	3.99	3.32	3.88
2	3.32	2.60	3.71	3.57	2.82	2.77	2.66	2.53	3.58	3.20	2.62	2.68
3	2.67	2.22	3.11	3.45	3.04	3.48	3.02	2.92	3.34	3.26	2.56	3.45
4	2.61	2.07	2.93	3.16	2.86	2.80	3.07	2.62	2.96	3.86	2.58	3.54
5	2.60	2.31	2.34	3.47	2.60	2.90	2.78	2.58	2.61	4.32	3.12	2.76
6	2.75	2.45	3.70	3.87	2.86	2.04	2.72	3.29	3.06	3.51	3.38	2.93
7	3.21	3.43	2.93	3.22	3.58	2.59	2.65	2.73	4.40	4.01	4.60	3.28
8	2.78	2.96	2.88	3.82	3.56	3.68	2.56	2.53	4.30	2.91	4.01	2.82
9	2.65	2.40	2.90	3.86	3.58	3.17	2.60	3.66	3.42	4.26	5.33	2.73
10	2.38	2.35	2.80	3.82	3.87	2.76	3.24	3.77	2.89	3.77	4.47	2.46
11	2.53	3.06	3.29	3.86	3.31	2.74	2.42	2.83	3.03	3.47	3.82	2.27
12	3.14	2.37	2.92	3.84	2.90	2.73	3.25	3.32	3.71	3.34	4.20	2.99
13	2.54	2.75	2.98	3.01	3.63	2.77	3.19	3.65	3.33	2.82	4.19	2.72
14	2.86	2.36	3.36	3.75	3.15	3.48	3.06	2.82	4.56	2.04	4.87	3.07
15	3.65	2.01	3.48	3.54	2.98	3.71	3.38	3.18	4.65	2.79	3.95	3.18
16	2.71	2.99	3.66	3.15	2.46	2.94	2.23	2.76	3.87	4.18	4.71	3.57
17	3.62	2.84	3.84	2.23	3.44	2.86	2.21	2.49	3.79	4.11	4.38	3.38
18	2.97	2.37	3.65	2.63	2.75	2.59	2.67	3.41	3.54	4.03	5.23	4.76
19	2.94	2.48	3.80	2.57	3.74	3.30	2.83	3.84	4.40	3.25	4.89	2.81
20	3.14	2.98	3.46	2.95	2.84	3.39	3.42	3.99	2.68	3.61	3.15	2.83
21	2.75	3.13	3.08	3.15	3.34	3.48	3.31	2.95	4.03	5.36	3.23	3.04
22	3.22	2.30	3.50	3.20	3.09	2.83	4.67	3.01	4.68	3.39	3.42	2.56
23	3.04	2.35	2.94	3.37	4.01	2.47	3.59	3.45	3.31	4.14	4.09	2.89
24	2.60	3.07	3.12	3.12	4.05	3.17	3.27	3.13	3.98	2.58	3.53	2.63
25	3.31	3.12	3.06	3.54	3.63	3.78	2.85	3.04	3.68	3.88	4.86	2.42
26	3.10	2.95	2.66	3.32	4.03	3.17	3.03	2.57	4.85	3.54	4.59	2.48
27	2.47	3.92	2.78	3.82	3.70	2.99	2.76	2.73	4.73	3.36	4.44	2.16
28	3.66	3.12	2.76	3.82	2.47	2.55	3.02	2.72	3.86	3.17	3.61	3.39
29	2.94		2.41	3.93	2.31	2.83	2.97	2.94	3.99	2.78	2.90	3.51
30	2.73		3.11	3.76	2.76	2.73	3.83	3.82	3.61	3.26	3.36	2.60
31	3.42		3.25		2.77		3.49	2.83		4.29		2.60
Promedio	3.0	2.7	3.2	3.4	3.2	3.0	3.0	3.1	3.8	3.6	3.9	3.0
Nº Datos	31	28	31	30	31	30	31	31	30	31	30	31
Desv. Est	0.4	0.5	0.4	0.4	0.5	0.4	0.5	0.4	0.6	0.7	0.8	0.5
Min	2.4	2.0	2.3	2.2	2.3	2.0	2.2	2.5	2.6	2.0	2.6	2.2
Max	3.7	3.9	3.8	4.0	4.1	3.8	4.7	4.0	4.9	5.4	5.3	4.8

EVAPOTRNSPIRACIÓN DE REFERENCIA (ET_o) ESTIMADO CON RNA - 6**ESTACIÓN PUTINA - (año 2013)**

DIA	MESES											
	ENE.	FEB.	MAR.	ABR.	MAY.	JUN.	JUL.	AGO.	SET.	OCT.	NOV.	DIC.
1	3.45	3.10	3.44	4.04	3.27	2.87	3.24	3.83	4.13	4.72	3.73	4.90
2	3.31	2.87	3.77	3.43	3.08	3.07	3.18	3.23	3.77	3.63	3.19	4.01
3	3.19	2.10	2.98	3.82	3.45	3.61	3.30	3.22	3.44	3.89	2.51	4.58
4	3.33	2.51	3.20	2.93	3.63	2.84	3.55	3.20	3.31	4.17	3.11	3.96
5	2.74	2.40	3.26	3.28	3.38	3.07	2.78	3.17	3.05	5.00	3.11	3.56
6	3.47	2.65	3.67	3.51	3.18	2.43	3.46	4.25	3.19	4.19	3.68	3.49
7	3.77	2.62	3.38	2.78	3.38	2.96	3.45	3.45	4.51	4.66	3.87	3.71
8	2.79	2.85	3.32	3.49	3.36	4.15	3.13	3.06	4.51	4.09	3.86	3.47
9	3.02	2.36	3.34	3.45	3.41	3.44	2.94	4.07	3.76	4.83	5.23	3.64
10	2.57	2.86	3.42	3.52	3.75	3.16	3.35	3.78	3.23	4.49	4.42	3.00
11	2.52	3.10	3.72	3.94	3.28	3.09	2.73	3.26	3.44	4.20	3.92	2.53
12	2.54	3.04	3.64	4.37	3.37	3.32	3.29	3.61	4.08	3.92	3.79	2.60
13	2.24	2.82	3.73	3.75	3.35	3.00	3.21	4.11	3.87	2.63	3.63	2.74
14	3.37	2.75	3.31	3.41	3.47	3.76	2.81	3.10	4.69	2.21	4.55	3.25
15	3.90	2.38	2.43	3.63	3.25	3.99	3.62	3.50	4.92	2.68	4.67	3.20
16	2.91	3.76	3.04	3.42	2.55	3.17	2.63	3.79	3.97	4.78	4.44	3.38
17	3.33	3.67	3.25	2.80	2.84	3.20	2.67	3.45	3.98	4.29	4.47	3.86
18	3.55	3.43	2.83	3.63	2.66	3.12	2.64	3.58	3.69	4.71	5.56	4.75
19	3.00	3.23	3.97	2.93	3.06	4.23	2.72	4.11	4.09	4.30	5.14	3.11
20	2.80	3.18	3.68	3.01	3.50	3.65	3.50	4.14	3.57	4.39	4.91	3.34
21	3.12	3.24	3.54	3.06	3.76	3.68	3.47	3.34	4.41	5.69	4.67	3.05
22	2.86	2.44	4.17	3.38	3.39	3.48	4.62	3.47	4.74	4.24	2.89	3.03
23	3.12	2.94	3.98	3.51	3.98	3.07	3.75	3.75	3.49	4.04	3.50	4.23
24	3.09	3.87	3.93	3.66	3.69	3.77	3.32	2.40	4.27	3.02	4.17	2.99
25	3.99	3.94	4.04	3.71	3.47	3.91	3.14	2.45	4.45	3.61	5.15	2.67
26	3.70	3.55	3.41	3.37	3.95	3.31	3.31	2.70	4.92	2.90	4.16	3.00
27	3.31	3.71	3.01	3.99	3.63	3.27	3.10	2.95	4.77	3.40	4.46	2.94
28	3.95	2.80	3.15	4.12	2.97	2.82	3.07	2.11	3.94	3.13	3.64	3.04
29	3.39		3.21	4.15	2.97	3.05	3.07	2.60	4.23	3.42	3.67	4.13
30	3.00		3.48	3.98	3.44	2.93	3.83	4.10	3.69	3.77	4.29	3.57
31	3.54		3.58		3.51		3.92	3.27		4.37		3.07
Promedio	3.2	3.0	3.4	3.5	3.4	3.3	3.3	3.4	4.0	4.0	4.1	3.4
Nº Datos	31	28	31	30	31	30	31	31	30	31	30	31
Desv. Est	0.4	0.5	0.4	0.4	0.3	0.4	0.4	0.6	0.5	0.8	0.7	0.6
Min	2.2	2.1	2.4	2.8	2.6	2.4	2.6	2.1	3.1	2.2	2.5	2.5
Max	4.0	3.9	4.2	4.4	4.0	4.2	4.6	4.3	4.9	5.7	5.6	4.9

EVAPOTRNSPIRACIÓN DE REFERENCIA (ET_o) ESTIMADO CON RNA - 6**ESTACIÓN MUÑANI - (año 2013)**

DIA	MESES											
	ENE.	FEB.	MAR.	ABR.	MAY.	JUN.	JUL.	AGO.	SET.	OCT.	NOV.	DIC.
1	3.45	3.10	3.44	4.04	3.27	2.87	3.24	3.83	4.13	4.72	3.73	4.90
2	3.31	2.87	3.77	3.43	3.08	3.07	3.18	3.23	3.77	3.63	3.19	4.01
3	3.19	2.10	2.98	3.82	3.45	3.61	3.30	3.22	3.44	3.89	2.51	4.58
4	3.33	2.51	3.20	2.93	3.63	2.84	3.55	3.20	3.31	4.17	3.11	3.96
5	2.74	2.40	3.26	3.28	3.38	3.07	2.78	3.17	3.05	5.00	3.11	3.56
6	3.47	2.65	3.67	3.51	3.18	2.43	3.46	4.25	3.19	4.19	3.68	3.49
7	3.77	2.62	3.38	2.78	3.38	2.96	3.45	3.45	4.51	4.66	3.87	3.71
8	2.79	2.85	3.32	3.49	3.36	4.15	3.13	3.06	4.51	4.09	3.86	3.47
9	3.02	2.36	3.34	3.45	3.41	3.44	2.94	4.07	3.76	4.83	5.23	3.64
10	2.57	2.86	3.42	3.52	3.75	3.16	3.35	3.78	3.23	4.49	4.42	3.00
11	2.52	3.10	3.72	3.94	3.28	3.09	2.73	3.26	3.44	4.20	3.92	2.53
12	2.54	3.04	3.64	4.37	3.37	3.32	3.29	3.61	4.08	3.92	3.79	2.60
13	2.24	2.82	3.73	3.75	3.35	3.00	3.21	4.11	3.87	2.63	3.63	2.74
14	3.37	2.75	3.31	3.41	3.47	3.76	2.81	3.10	4.69	2.21	4.55	3.25
15	3.90	2.38	2.43	3.63	3.25	3.99	3.62	3.50	4.92	2.68	4.67	3.20
16	2.91	3.76	3.04	3.42	2.55	3.17	2.63	3.79	3.97	4.78	4.44	3.38
17	3.33	3.67	3.25	2.80	2.84	3.20	2.67	3.45	3.98	4.29	4.47	3.86
18	3.55	3.43	2.83	3.63	2.66	3.12	2.64	3.58	3.69	4.71	5.56	4.75
19	3.00	3.23	3.97	2.93	3.06	4.23	2.72	4.11	4.09	4.30	5.14	3.11
20	2.80	3.18	3.68	3.01	3.50	3.65	3.50	4.14	3.57	4.39	4.91	3.34
21	3.12	3.24	3.54	3.06	3.76	3.68	3.47	3.34	4.41	5.69	4.67	3.05
22	2.86	2.44	4.17	3.38	3.39	3.48	4.62	3.47	4.74	4.24	2.89	3.03
23	3.12	2.94	3.98	3.51	3.98	3.07	3.75	3.75	3.49	4.04	3.50	4.23
24	3.09	3.87	3.93	3.66	3.69	3.77	3.32	2.40	4.27	3.02	4.17	2.99
25	3.99	3.94	4.04	3.71	3.47	3.91	3.14	2.45	4.45	3.61	5.15	2.67
26	3.70	3.55	3.41	3.37	3.95	3.31	3.31	2.70	4.92	2.90	4.16	3.00
27	3.31	3.71	3.01	3.99	3.63	3.27	3.10	2.95	4.77	3.40	4.46	2.94
28	3.95	2.80	3.15	4.12	2.97	2.82	3.07	2.11	3.94	3.13	3.64	3.04
29	3.39		3.21	4.15	2.97	3.05	3.07	2.60	4.23	3.42	3.67	4.13
30	3.00		3.48	3.98	3.44	2.93	3.83	4.10	3.69	3.77	4.29	3.57
31	3.54		3.58		3.51		3.92	3.27		4.37		3.07
Promedio	3.2	3.0	3.4	3.5	3.4	3.3	3.3	3.4	4.0	4.0	4.1	3.4
Nº Datos	31	28	31	30	31	30	31	31	30	31	30	31
Desv. Est	0.4	0.5	0.4	0.4	0.3	0.4	0.4	0.6	0.5	0.8	0.7	0.6
Min	2.2	2.1	2.4	2.8	2.6	2.4	2.6	2.1	3.1	2.2	2.5	2.5
Max	4.0	3.9	4.2	4.4	4.0	4.2	4.6	4.3	4.9	5.7	5.6	4.9