



PERÚ

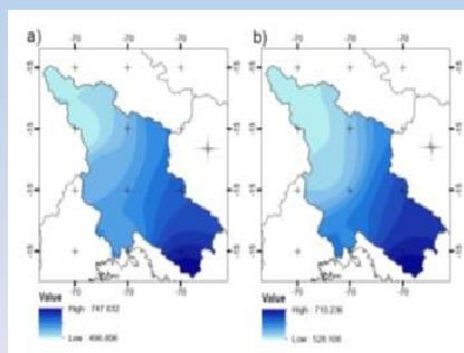
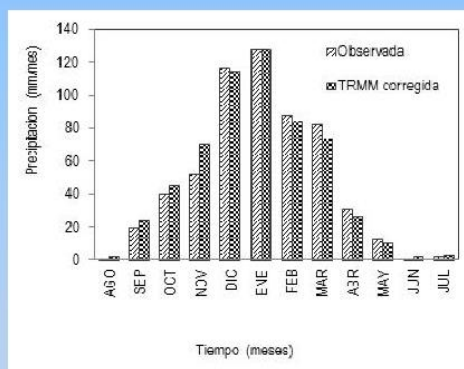

Ministerio
del Ambiente

Servicio Nacional de Meteorología e
Hidrología - SENAMHI

PROGRAMA PRESUPUESTAL, REDUCCION DE VULNERABILIDAD Y
ATENCIÓN DE EMERGENCIAS POR DESASTRES - PREVAE



VALIDACIÓN Y CORRECCIÓN DE LA PRECIPITACIÓN ESTIMADA POR EL SATÉLITE TRMM USANDO REDES NEURONALES ARTIFICIALES – APLICACIÓN CUENCAS DE PUNO



DICIEMBRE - 2013

VALIDACION Y CORRECCION DE LA PRECIPITACION ESTIMADA POR SATELITE TRMM APLICANDO REDES NEURONALES ARTIFICIALES

VALIDATION AND CORRECTION OF SATELLITE TRMM RAINFALL ESTIMATES APPLYING ARTIFICIAL NEURAL NETWORK

LUJANO LAURA¹, OSCAR FELIPE ²

¹Ingeniero Agrícola, profesional hidrólogo del SENAMHI

²Ingeniero Agrícola, profesional hidrólogo del SENAMHI

RESUMEN

Este trabajo fue aplicado en la cuenca del río Huancané, de la región Hidrográfica del Titicaca, con el objetivo de verificar la calidad de la información de las estimaciones de precipitación del satélite TRMM producto mensual 3B43 y proponer una metodología de corrección basado en RNA's (Redes Neuronales Artificiales). Para el análisis de los datos se utilizó información de 7 estaciones meteorológicas del SENAMHI con información de precipitación del periodo 1998 – 2010, los cuales fueron comparados con las estaciones virtuales del TRMM con datos sin corregir y luego con los datos corregidos mediante RNA's. Para la aplicación del modelo de RNA's, en su etapa de entrenamiento y validación, se trabajó con el 70% y 30% del total de datos respectivamente con lo cual se verifica que el modelo de corrección propuesto mejora la bondad de ajuste entre la precipitación observada y las estimaciones del TRMM; evaluados a través del coeficiente de determinación, la raíz del error medio cuadrático y el BIAS; la significancia estadística de estos índices fue cuantificada aplicando el método bootstrap incorporado

en el código FITEVAL. Los resultados obtenidos con el modelo de corrección de datos del TRMM indican mejoras significativas en relación a los datos originales sin corregir; así tenemos que a nivel puntual el coeficiente de determinación sube de 51% y 71% a 79% y 91%; el coeficiente de Nash sube de 15% y 68% a 80% y 91%, para el grupo de estaciones evaluadas. Seguidamente para completar este proceso se optó por realizar la interpolación espacial de los datos observados y del TRMM para la obtención de las series areales de precipitación, donde se obtiene también mejoras significativas en los indicadores de ajuste para los datos corregidos, así tenemos que el coeficiente de determinación sube de 73% a 93%; mientras que el coeficiente de eficiencia de Nash sube de 71% a 93%. Se concluye que las estimaciones de satélite del TRMM mediante una adecuada calibración y/o corrección se convierte en una valiosa alternativa para el monitoreo hidrometeorológico y modelización de la disponibilidad hídrica en cuencas pobremente instrumentadas.

Palabras Claves: TRMM, Redes neuronales, backpropagation.

ABSTRACT

This work was applied in the basin of Huanacáné, region Hydrographic Titicaca, in order to verify the information quality of precipitation estimates from TRMM monthly product 3B43 and propose a method of correction based on RNA's (Network artificial neural). To analyze the data we used information from seven weather stations with information SENAMHI precipitation period from 1998 to 2010, which were compared with the TRMM virtual stations with uncorrected data with the data and then corrected by RNA's. For the application of model RNA's, during her training and validation, we worked with 70% and 30% of the total data respectively thus verifies that the model proposed correction improves the goodness of fit between observed precipitation and TRMM estimates, evaluated through the coefficient of determination, root mean square error and bias, the statistical significance of these indices was quantified applying bootstrap code incorporated in FITEVAL.

The results obtained with the correction model TRMM data show significant improvements over the original uncorrected data, so we have to point at the coefficient of determination goes from 51% and 71% to 79% and 91%, the coefficient Nash passes of 15% and 68% to 80% and 91% for the group of stations evaluated. Then to complete this process we chose to perform spatial interpolation of the observed data and the TRMM to obtain areal precipitation series, which is also obtained

significant improvements in indicators of adjustment to the corrected data, so we have that the coefficient determination rises from 73% to 93%, while the Nash efficiency coefficient rises from 71% to 93%. We conclude that the TRMM satellite estimates through proper calibration and / or correction becomes a valuable alternative to hydro-meteorological monitoring and modeling of water availability in ungauged catchments

Keywords: TRMM, neural networks, backpropagation.

INTRODUCCIÓN

La precipitación es una de las variables meteorológicas más importantes para determinar los procesos hidrológicos en una cuenca, por ello el TRMM (Tropical Rainfall Measuring Mission, NASA & JAXA), es una conjunción de exploración espacial entre la NASA y la Agencia de Exploración Aeroespacial Japonesa, diseñada para monitorear y estudiar las lluvias tropicales y subtropicales, lanzado el 27 de noviembre de 1997 a una altura de 350 km, brindando información de alta cobertura espacial y alta resolución temporal. La lluvia del TRMM, es producida por el algoritmo de precipitación global (3B42_V6), de resolución temporal 3 horas y resolución espacial de 0.25 x 0.25 grados (25*25 km). Existen otros algoritmos basados en satélites, como el Algoritmo PERSIANN (Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks) desarrollado por Sorooshian et al (2000, 2005) del Centro para la Hidrometeorología y Sensores Remotos (CHRS) de USA.

Son muchas las aplicaciones hidrológicas del TRMM y sus productos derivados, como por ejemplo el monitoreo hidrometeorológico y pronóstico de crecientes en tiempo real. En el Perú los principales estudios de corrección del TRMM son realizados por Lavado R. (2009) en la región andina. Las redes neuronales se han utilizado para el pronóstico de caudales en la cuenca del río Ramis (Laqui, V.2010).

El objetivo principal de este trabajo es desarrollar una metodología de corrección de los datos mensuales del TRMM a paso de tiempo mensual, utilizando Redes neuronales artificiales, como alternativa frente a otros métodos que se basan en procesos lineales.

MATERIALES Y MÉTODOS

Descripción general de la cuenca

La cuenca del río Huancané geográficamente se ubica entre las coordenadas UTM WGS84; Este (376030 – 468557), Norte (8301965 – 8397410) y altitud comprendida entre (3,806 - 5,100 msnm). La zona de estudio forma parte de la vertiente del Titicaca y Sistema TDPS (lado Peruano). Se caracteriza como un sistema de cuenca endorreica, ubicada entre las provincias de Huancané, Moho, Azángaro y San Antonio de Putina en el Departamento de Puno. La superficie total de la cuenca del río Huancané es de 3,631.21 Km².



Figura N° 1 Ubicación del área de estudio

Información utilizada

Series mensuales de Precipitación consistentes y continuas para el periodo 1998-2010 para las estaciones listadas en el Cuadro 1. Para el caso de las estaciones virtuales del TRMM, las series utilizadas corresponde al centroide de la grilla de 0.25*0.25 grados. Para seleccionar los centroides a comparar con las estaciones terrenas se tuvo en cuenta dos criterios el área de influencia de la grilla y los polígonos de Thiessen construidos en base a las estaciones meteorológicas, según la disposición la Figura 2. Los datos del TRMM fueron descargados del portal <http://disc2.nascom.nasa.gov/Giovanni/tovas/> La cota de la estación virtual se ha obtenido por intercepción con el DEM-90 m del SRTM

Cuadro 1: Listado de estaciones meteorológicas

Estación	lat (grad)	lon (grad)	altitud msnm
Huancané	-15.202	-69.754	3990.00
Huaraya-Moho	-15.388	-69.485	3990.00
Putina	-14.915	-69.868	3878.00
Cojata	-15.026	-69.364	4300.00
Muñani	-14.767	-69.952	3950.00
Ananea	-14.679	-69.535	4650.00
Crucero	-14.363	-70.024	4150.00

Cuadro 2. Centroides de grilla del TRMM

Estación	lat (grad)	lon (grad)	altitud msnm
TRMM - 270	-15.250	-69.750	3817.00
TRMM - 271	-15.250	-69.500	3916.00
TRMM - 295	-15.000	-69.750	3986.00
TRMM - 296	-15.000	-69.500	4777.00
TRMM - 320	-14.750	-70.000	4113.00
TRMM - 322	-14.750	-69.500	4829.00
TRMM - 375	-14.250	-70.000	4862.00

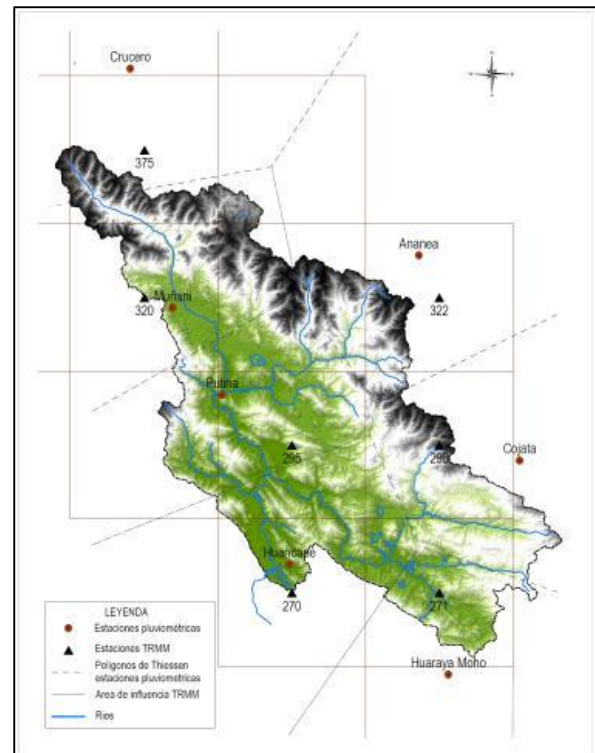


Figura 2. Localización de las Estaciones meteorológicas y grillas del TRMM

METODOLOGIA

Se utilizaron 07 estaciones meteorológicas que están ubicadas dentro y fuera de la cuenca, las cuales pertenecen al Servicio Nacional de Meteorología e Hidrología (SENAMHI) y 07 estaciones virtuales correspondientes al TRMM, con un periodo de registro de enero 1998 hasta diciembre del 2010. Las series observadas y del TRMM fueron evaluadas a nivel puntual y espacial.

A nivel puntual se compara la estación terrena con el centroide de la grilla del TRMM seleccionada. Primero se hace el análisis temporal de toda la serie continua y luego se compara el comportamiento estacional de la Precipitación.

El análisis espacial de la precipitación se obtiene mediante la interpolación con el método de Krigging, construyendo la serie

temporal de los valores areales para los datos observados como los del TRMM.

Para evaluar la bondad de ajuste de la precipitación observada y del TRMM antes y después de la corrección se utiliza los indicadores estadísticos de Nash-Sutcliffe (NSE), Raíz del Error Medio Cuadrático (RMSE), BIAS y el coeficiente de determinación (R^2).

$$NSE = \left(1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}\right) * 100$$

$$BIAS = \frac{\sum_{i=1}^N (\hat{y}_i - y_i)}{\sum_{i=1}^N y_i} * 100$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}}$$

$$R^2 = \frac{scE}{scG} = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

Donde, y_i representa el valor observado, \hat{y}_i el valor calculado, n número de observaciones y \bar{y} el promedio de los datos observados

La significancia estadística de estos indicadores, fundamentalmente el NSE y RMSE, para el conjunto de las estaciones, fue evaluada mediante la técnica de Bootstrap automatizada en el código en matlab FITEVAL (Ritter A., Muñoz R). El Bootstrap es una técnica de remuestreo consiste en reutilizar los datos disponibles

como si estos constituyeran una población de la cual extraer repetidas muestras, Es decir, se asume que la matriz de valores observados y calculados constituyen los valores de toda la población, y se van extrayendo con reemplazo M muestras (de tamaño N), de conjuntos de valores observados y calculados. Para cada remuestreo se calcula el $RMSE$ y el NSE . De esta forma se construye empíricamente la distribución de probabilidad de ambos indicadores.

El código FITEVAL establece categorías de valorización de la bondad de ajuste de los indicadores estadísticos, tal como se indica en el Cuadro 1.

Cuadro 1. Criterios para evaluar la bondad de ajuste de los indicadores


Evaluación	RMSE/SD	NSE
Muy buena	≤30%	≥0.91
Buena	30-40%	0.84-0.91
Aceptable	40-60%	0.75-0.84
No aceptable	>50%	<0.75

SD: Desviación estándar de los valores observados

Redes Neuronales Artificiales (RNA's)

Las redes neurales funcionan según el principio de aprendizaje del conjunto de entrenamiento. Antes de la formación, la red no tiene ningún conocimiento sobre el problema, lo que esto hace que a medida del entrenamiento las redes aprenden y sean capaces de proporcionar resultados exitosos.

Figura N° 3 de la neurona biológica a la artificial




En el presente estudio se utilizó el perceptron multicapa la cual es una red neuronal formada por múltiples capas y esto le permite resolver problemas que no son linealmente separables.

Arquitectura del perceptron multicapa (MLP)

La arquitectura del Perceptron Multicapa, surge en una combinación de esfuerzos de diversos autores ([Werbos, 1974], [Werbos, 1988], [Werbos, 1989], [Parker, 1985], [Parker, 1987], [Rumelhart et al., 1986]), por corregir las limitaciones que las redes iniciales, Adaline y Perceptron tenían, sobre todo en cuanto a separabilidad de funciones no lineales.

La idea de combinar varios perceptrones para poder conseguir relaciones no lineales, consiguió delimitar un proceso de aprendizaje que fuera capaz de modificar los pesos de la red de un modo eficiente, a esta regla de aprendizaje se le llamó algoritmo backpropagation o regla delta generalizada y es, hoy en día, uno de los algoritmos de aprendizaje más utilizado y estudiado para todo tipo de redes.

Figura N° 4 Arquitectura RNA's perceptron multicapa



Aprendizaje

Según Hilera y Martínez (1995) para que una red aprenda se debe de seguir 06 pasos importantes:

Paso 1: Inicializar los pesos de la red con valores pequeños aleatorios.

Paso 2: Presentar un patrón de entrada, X_p : $X_{p1}, X_{p2}, \dots, X_{pn}$, y especificar la salida deseada que debe generar la red: d_1, d_2, \dots, d_m .

Paso 3: Calcular la salida actual de la red, para ello presentamos las entradas a la red y vamos calculando la salida que presenta cada capa hasta llegar a la capa de salida esta será la salida de la red y_1, y_2, \dots, y_m . Los pasos son los siguientes:

- Se calculan las entradas netas para las neuronas ocultas procedentes de las neuronas de entrada. Para una neurona j oculta:

$$net_{pj}^h = \sum_{i=0}^N w_{ji}^h x_{pi} + \theta_j^h \quad (1)$$

En donde el índice h se refiere a magnitudes de la capa oculta (hidden); el subíndice p , al p -ésimo vector de entrenamiento, y j a la j -ésima neurona oculta. El término θ puede ser opcional, pues actúa como una entrada más.

- Se calculan las salidas de las neuronas ocultas utilizando una función de activación f .

$$y_{pj}^h = f_j^h(\text{net}_{pj}^h) \quad (2)$$

- Se realizan los mismos cálculos para obtener las salidas de las neuronas de salida (capa o: output)

$$\text{net}_{pk}^o = \sum_{j=1}^N w_{kj}^o y_{pj}^o + \theta_k^o \quad (3)$$

$$y_{pk}^o = f_k^h(\text{net}_{pk}^o) \quad (4)$$

Para minimizar el error (fórmula en el Paso 6) la función f debe ser derivable, lo que implica la imposibilidad de utilizar la función escalón. En general se utilizan dos tipos de función de activación: la función lineal ($f(\text{net}_{jk}) = (\text{net}_{jk})$) y la función sigmoidea definida por la ecuación:

$$f(\text{net}_{jk}) = \frac{1}{1 + e^{-\text{net}_{jk}}} \quad (5)$$

La elección de esta función depende de la forma en que se decida representar los datos: si se desea que las neuronas de salida sean binarias, se utiliza la función sigmoidea, puesto que la función es casi biestable y además, derivable.

Paso 4: Calcular los términos de error para todas las neuronas.

Después que todas las neuronas de la red tienen un valor de activación asociado para un patrón de entrada dado, el algoritmo continúa encontrando el error que se presenta para cada neurona, excepto las de la capa de entrada. Para la neurona k de la capa de salida, si la respuesta es (y_1, y_2, \dots, y_M) , dicho error (δ) se puede escribir como:

$$\delta_{pk} = (d_{pk} - y_{pk}) f_k'(\text{net}_{pk}) \quad (6)$$

y para la función sigmoidea en particular:

$$\delta_{pk} = (d_{pk} - y_{pk}) y_{pk} (1 - y_{pk}) \quad (7)$$

Si la neurona j no es de salida, entonces la derivada parcial del error no puede ser evaluada directamente. Por tanto, se obtiene el desarrollo a partir de valores que son conocidos y otros que pueden ser evaluados.

La expresión obtenida en este caso es:

$$\delta_{pj}^h = x_{pi} (1 - x_{pi}) \sum_k \delta_{pk} w_{kj} \quad (8)$$

observamos que el error en las capas ocultas depende de todos los términos del error de la capa de salida. De aquí el nombre de propagación hacia atrás. En particular para la función sigmoidea.

Donde k se refiere a todas las neuronas de la capa superior a la de la neurona j . Así el error que se produce en una neurona oculta es proporcional a la suma de los errores conocidos que se producen en las neuronas a las que está conectada la salida de la misma, multiplicando cada uno por el peso de la conexión. Los umbrales internos de las neuronas se adaptan de forma similar,

considerando que están conectados con pesos desde entradas auxiliares de valor constante.

Paso 5: Actualización de pesos

Para ello utilizamos el algoritmo recursivo, comenzando por las neuronas de salida y trabajando hacia atrás hasta llegar a la capa de entrada, ajustando los pesos de la forma siguiente:

Para los pesos de las neuronas de la capa de salida:

$$w_{kj}(t+1) = w_{kj}(t) + \Delta w_{kj}^o(t+1); \quad (9)$$

$$\Delta w_{kj}^o(t+1) = \alpha \delta_{pk} y_{pj}^h \quad (10)$$

y para los pesos de las neuronas de la capa oculta:

$$w_{ji}(t+1) = w_{ji}(t) + \Delta w_{ji}^h(t+1); \quad (11)$$

$$\Delta w_{ji}^h(t+1) = \alpha \delta_{pj}^h y_{pi} \quad (12)$$

$$\gamma((w_{ji}(t) - w_{ji}(t-1)))$$

$$\gamma((w_{kj}(t) - w_{kj}(t-1)))$$

En ambos casos, para acelerar el proceso de aprendizaje, se incluye una tasa de aprendizaje que varía entre 0 y 1, dependiendo del problema a solucionar. También se puede añadir un término de momento, para corregir la dirección del error, de valor: γ en el caso de una neurona de salida, y cuando se trata de una neurona oculta; la constante γ es la tasa de momento; y un tercer parámetro β para acelerar la convergencia del proceso.

Paso 6: El proceso se repite hasta que el término de error

$$E_p = \frac{1}{2} \sum_{k=1}^M \delta_{pk}^2 \quad (13)$$

resulta aceptablemente pequeño para cada uno de los patrones aprendidos.


Redes neuronales artificiales (RNA's) en la corrección de lluvias estimada por satélite

Arquitectura

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.

En el presente trabajo solo se tiene una variable de entrada el cual está representado por la precipitación estimada de satélite TRMM, donde la arquitectura de la red ha sido conformada por una neurona en la capa de entrada, de 3 a 7 neuronas en la capa oculta y una neurona en la capa de salida.

Figura N° 3 Arquitectura de la red



Entrenamiento de modelos

Para el entrenamiento de los modelos de RNA's, se ha utilizado el 70% de datos disponibles de precipitaciones TRMM y observadas, periodo que comprende de 1998 a 2006, el algoritmo de aprendizaje para el tipo de red perceptrón multicapa, es el Backpropagation, con una tasa de aprendizaje igual a 0.25 y un factor momento igual a 0.90. En general, el valor de la tasa de aprendizaje (α) suele estar comprendida entre 0.05 y 0.25, (Hilera y Martínez 1995) y El factor momento suele tomar un valor próximo a 1 por ejemplo 0.9 (Rumelhart, Hinton y Williams, 1986).

El número de conexiones de los modelos de RNA's varia de 6 a 14, el número de iteraciones de 11 a 11640 y que fueron necesarios para minimizar el termino de error ($E_p \leq 0.0000001$ o $E_p \leq 10^{-7}$).

Validación

Una vez que ha terminado el proceso de aprendizaje y los pesos de la red han sido calculados es importante validar los modelos utilizados. Pueden utilizarse gráficos del tipo de los scatter plots, box and whiskers, indicadores estadísticos u otros.

En el presente trabajo para esta fase se han utilizado 04 (cuatro) años de datos observados y estimados por satélite TRMM corregidas, que comprende el periodo del 2007 al 2010

El análisis RNA's fue realizado con el programa Alyuda Neuro Intelligence 2.4, desarrollado por ALYUDA Research Company.

RESULTADOS

Análisis datos TRMM sin corregir

Comparación puntual de datos mensuales observados y del satélite

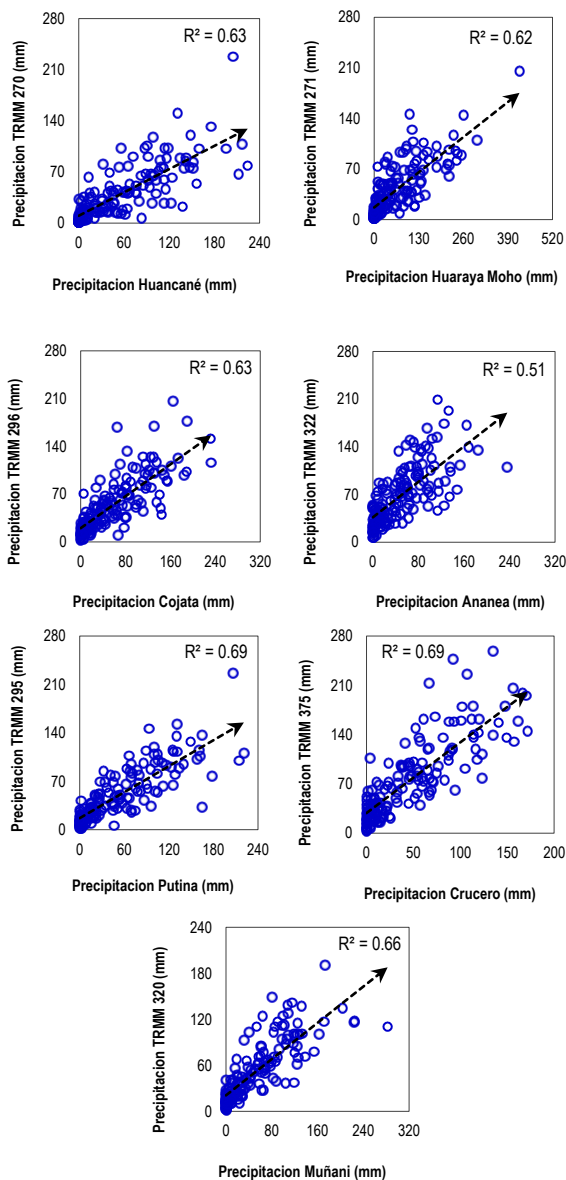
El total de datos de las lluvias del TRMM al ser comparados con las precipitaciones observadas de las estaciones meteorológicas muestran un coeficiente de Determinación comprendido entre el 50.9% (Estación Ananea) y 69% (Estación Putina), tal como se presenta en el Cuadro 3 y en los diagramas de dispersión de la Figura 5. Los resultados del Cuadro 3 indican una mayor tendencia a la subestimación de la precipitación del TRMM con respecto a los valores observados.

Cuadro N° 3. Indicadores estadísticos de la bondad de ajuste de los datos del TRMM

Estaciones	NASH E (%)	BIAS (%)	RMSE	R2 (%)
Huancane - TRMMs 270	54.4	-27.8	37.3	63.3
Huaraya Moho - TRMM 271	40.9	-37.6	57.8	61.7
Putina - TRMM 295	68.2	-4.8	29.4	69.0
Cojata - TRMM 296	61.8	-7.2	33.3	62.7
Muñani - TRMM 320	65.5	-1.3	31.9	66.3
Ananea - TRMM 322	30.3	36.9	38.4	50.9
Crucero - TRMM 375	15.0	60.9	42.6	68.7

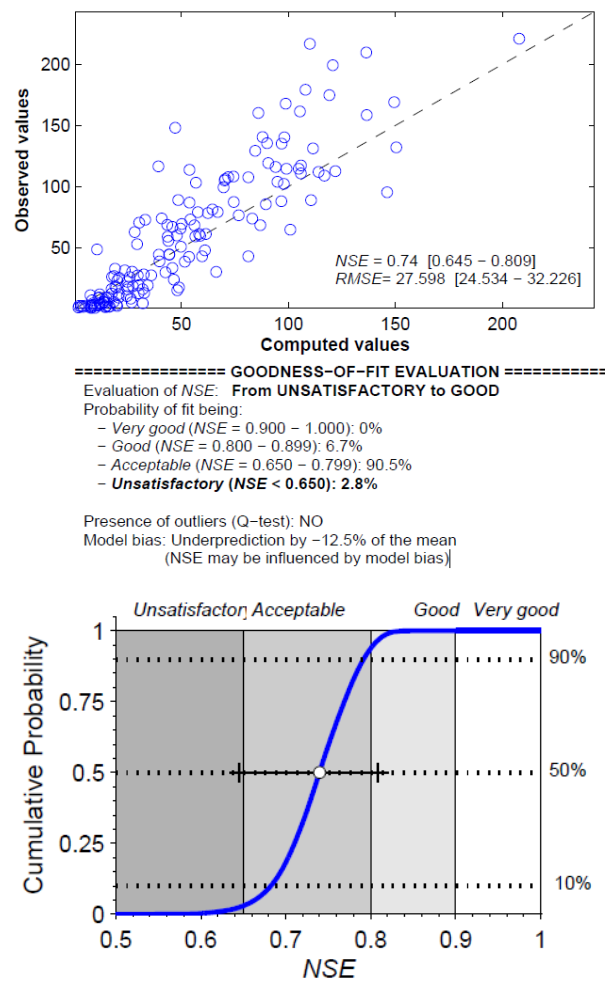
Para las estaciones virtuales ubicadas al noreste de la cuenca Huancané y por encima de los 4800,0 msnm se obtiene sobrestimación de la precipitación del TRMM.

Figura 5. Diagrama de dispersión datos observados y TRMM sin corregir



Con respecto a la significancia estadística del ajuste de los datos observados y del TRMM se obtiene para el conjunto de los datos evaluados una NSE de 74% y RMSE de 27.6; por otro lado la caracterización de la bondad del ajuste y la significancia estadística de estos indicadores, alcanza la categoría de “ajuste aceptable” al 95% de confianza, según los criterios del código FITEVAL tal como se puede apreciar en los diagramas de la Figura 6

Figura 6. Significancia estadística de la bondad de ajuste del NSE y RMSE del conjunto de datos observados y del TRMM



Comparación espacial de datos mensuales observados y del satélite

La comparación de los valores areales de la precipitación, para el periodo 1998-2010, obtenidos por los pluviómetros y por el TRMM dan un NSE de 71%, un RMSE de 27.6 y un R^2 de 73% y un BIAS de -8%. Las series mensuales generadas se presenta en la Figura 7, mientras que en la Figura 8 se presenta los promedios multimensuales, donde se observa con una mayor tendencia a la subestimación de los datos del TRMM en el periodo húmedo.

Figura 7. Precipitación media areal mensual con datos observados y del TRMM

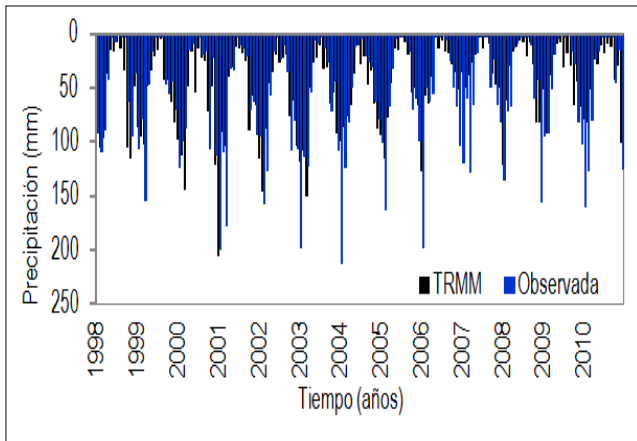



Figura 8. Promedios multimensuales de la precipitación areal observada y del TRMM



En los mapas interpolados de la precipitación anual observada y del TRMM de la Figura 9, así como la distribución espacial de los errores que se presenta en la Figura 10 se confirma una mayor tendencia a la subestimación de los datos del TRMM en la mayor superficie de la cuenca, con núcleos de hasta -181.4 mm en la zona norte de la cuenca, mientras que en la zona sur se aprecia núcleos de hasta 251.2 mm con sobrestimación.

Figura 9. Distribución espacial de la precipitación anual método de Kriging: a) observada, b) TRMM

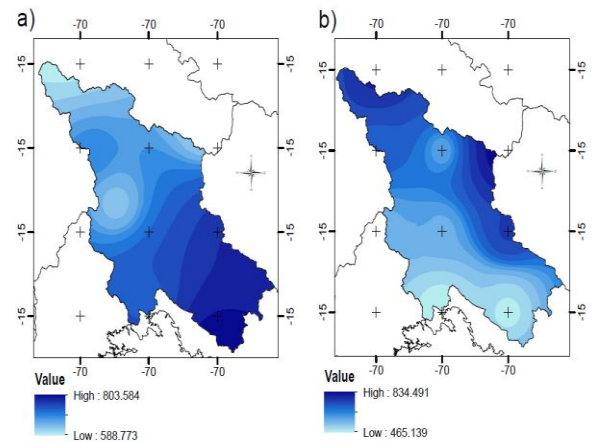
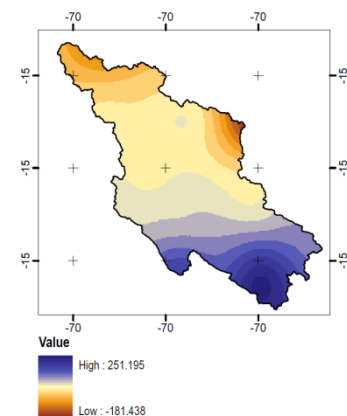


Figura 10. Distribución espacial de los errores del TRMM a nivel anual



Análisis de datos del TRMM corregidos

Las lluvias estimadas por satélite TRMM muestran bajos grados de confiabilidad en la zona de estudio respecto a las lluvias observadas, por lo tanto, estos datos se corrigieron en forma puntual utilizando modelos de Redes Neuronales Artificiales (RNA's).

Comparación puntual de datos mensuales observados y del satélite

La metodología de corrección propuesta para los datos del TRMM, logra mejorar los indicadores estadísticos de ajuste para todas las estaciones analizadas, tal como puede apreciarse en el Cuadro 4 y Figura 11.

Cuadro 4. Indicadores estadísticos de la bondad de ajuste de los datos del TRMM_c

Estaciones	NASH E (%)	BIAS (%)	RMSE	R ² (%)
Huancane - TRMM 270	85.3	-4.0	20.3	85.6
Huaraya Moho - TRMM 271	88.9	5.1	23.2	89.4
Putina - TRMM 295	79.6	1.2	21.5	80.4
Cojata - TRMM 296	85.3	-4.1	20.1	86.0
Muñani - TRMM 320	80.0	-4.7	20.7	81.0
Ananea - TRMM 322	91.0	-0.4	13.5	91.0
Crucero - TRMM 375	84.0	-8.3	16.7	85.5

Las mejoras más relevantes se obtienen para las estaciones de Crucero y Ananea que incrementan su NSE de 15% y 30% a 84% y 91%, respectivamente. La subestimación de la precipitación del TRMM_c se mantiene pero en menor magnitud.

Con respecto a la significancia estadística del ajuste de los datos observados y del TRMM_c se obtiene para el conjunto de los datos evaluados una NSE de 92.5% y RMSE de 13.1; por otro lado la caracterización de la bondad del ajuste y la significancia estadística de estos indicadores, alcanza la categoría de “ajuste muy bueno” al 95% de confianza, tal como puede apreciarse en los diagramas de la Figura 12.

Figura 11. Diagrama de dispersión entre lluvias observadas y TRMM_c

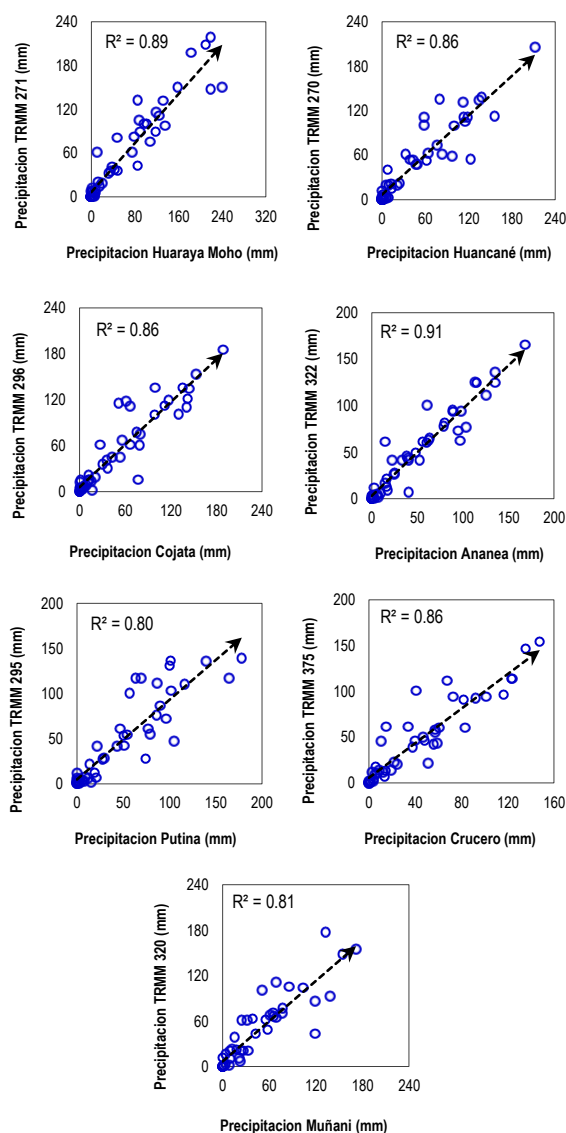
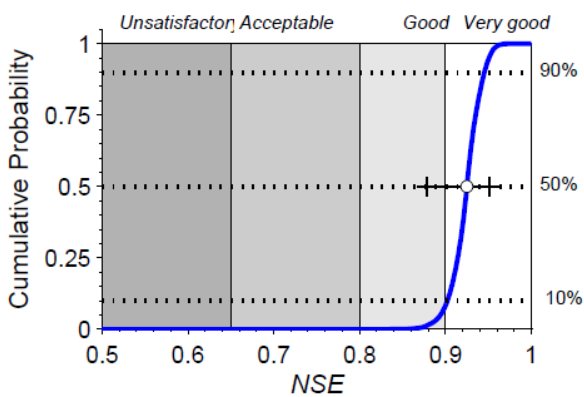
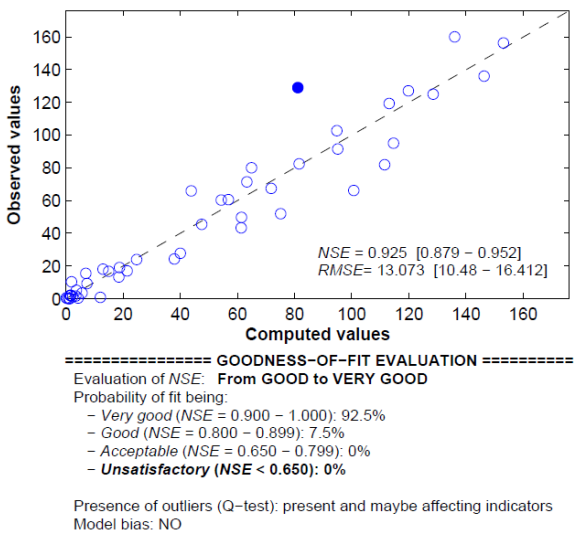


Figura 12. Significancia estadística de la bondad de ajuste del NSE y RMSE del conjunto de datos observados y del TRMM_c



Comparación espacial de datos mensuales observados y del satélite

A nivel espacial, con los datos del TRMM corregidos, se logra también mejorar la performance de los indicadores estadísticos de ajuste de la precipitación media areal; así tenemos que el NSE se incrementa a 93%; el RMSE baja a 13.49; el R^2 se incrementa a 93% y el BIAS alcanza 3%. Las series mensuales generadas se presenta en la Figura 13, mientras que en la Figura 14 se presenta los promedios multimensuales, donde se puede apreciar una menor

subestimación en el periodo húmedo y una leve sobrestimación en el periodo seco.

Figura 13. Precipitación media areal mensual con datos observados y del TRMM_c

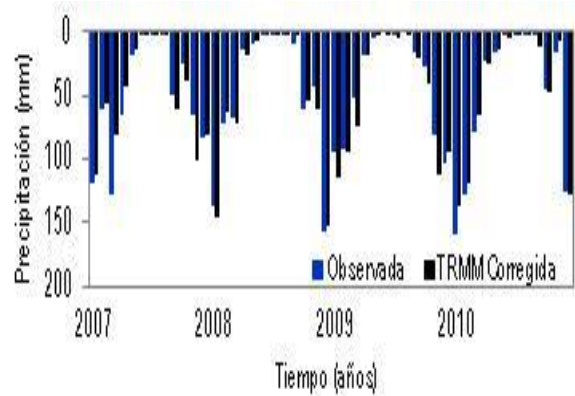
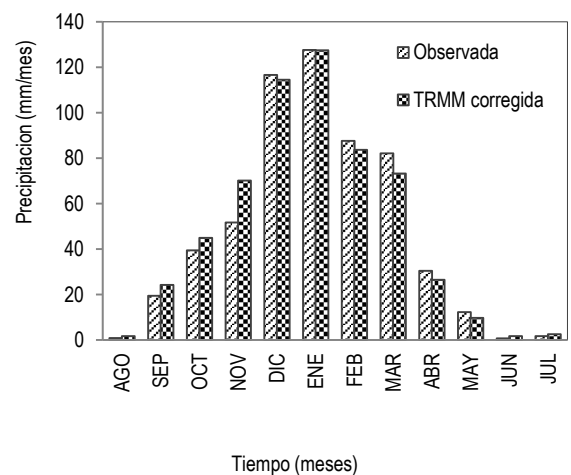


Figura 14. Promedios multimensuales de la precipitación areal observada y del TRMM



En los mapas interpolados de la precipitación anual de la precipitación observada y del TRMM corregido de la Figura 15, así como la distribución de los errores que se presenta en la Figura 16 se puede apreciar una mayor similitud en el comportamiento pluviométrico con diferencias mínimas en la distribución del error en toda la superficie de la cuenca. Al extremo norte de la cuenca se presenta subestimaciones de hasta -30 mm, mientras

que al extremo sur se obtiene sobrestimaciones de hasta 35.0 mm.

Figura 15. Distribución espacial de la precipitación método de Kriging: a) observada, b) TRMM corregido

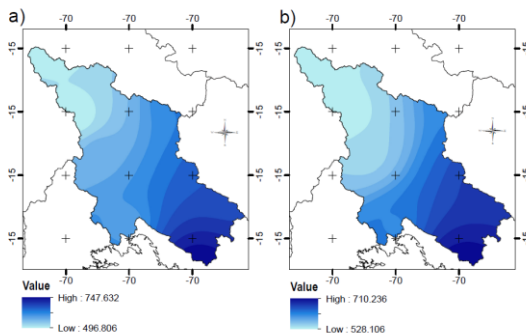



Figura 16. Distribución espacial de los errores del TRMM_c a nivel anual



CONCLUSIONES Y RECOMENDACIONES

CONCLUSIONES

- ✓ Las estimaciones satelitales del TRMM para la zona evaluada muestran una mayor tendencia a la subestimación de los datos observados en el periodo húmedo; sin embargo con el modelo de corrección propuesto la distribución de los sesgos es más uniforme en la cuenca y en menor magnitud.

- ✓ Mediante el presente trabajo, se estableció 01 modelo de red neuronal artificial que está en función de la precipitación de satélite TRMM, el cual nos permite corregir con buena aproximación las precipitaciones estimadas por satélite, el modelo propuesto es: MRNA ($P_{EST(t)}=f(P_{TRMM(t)})$).

- ✓ El modelo propuesto, presenta mejoras, debido a que se han obtenido para el conjunto de datos una NSE de 92% y un RMSE de 13.07, frente a NSE de 74% y RMSE de 27.59 de los datos sin corregir.

- ✓ A nivel espacial, los valores medios areales obtenidos con los datos corregidos del TRMM mejora en relación a los datos sin corregir; así tenemos que los indicadores estadísticos de ajuste como NSE pasa de 71% a 93%; el RMSE pasa de 27.6 a 13.49, el R^2 pasa de 73% a 93% y el BIAS pasa de -8% a 3%.

RECOMENDACIONES

Realizar similar análisis para el conjunto de las cuencas de la vertiente del Titicaca.

Evaluar el modelo de corrección con RNA's a datos diarios del TRMM

Realizar simulaciones hidrológicas incorporando los datos del TRMM corregidos.

BIBLIOGRAFIA

1. **Bishop C.** Neural Networks for Pattern Recognition, Oxford: Clarendon Press. 1995.
2. **Dölling O, Varas E.** Pronóstico de Caudales Nivales Usando Redes Neuronales Artificiales". XIX Congreso Latinoamericano de Hidráulica. Córdoba: Argentina. 2000.
3. **French MN, Krajewski WF, Cuykendall RR.** Rainfall forecasting in space and time using a neural network. Journal of Hydrology.1992.
4. **Freeman J, Skapura D.** Redes Neuronales: Algoritmos, aplicaciones y técnicas de programación. Delaware E. U. A. Addison Wesley Iberoamericana S. A. 1993.
5. **Haykin S.** Neural Networks and Learning Machines, 3ra ed. Prentice Hall. 2009
6. **Hilera JR, Martínez VJ.** Redes Neuronales Artificiales. Fundamentos, modelos y aplicaciones. Ra-ma Editorial. Madrid. 1996.
7. **Laqui VWF.** Aplicación de Redes Neuronales Artificiales a la Modelización y Previsión de Caudales Medios Mensuales del Rio Huancafé. Revista Peruana Geo-Atmosférica (RPGA), Senamhi - Perú. 2010.
8. **Lavado PR, Condom T.** Análisis espacio temporal de la precipitación en las zonas de montaña de Perú (1998-2007). Revista Peruana Geo-Atmosférica (RPGA), Senamhi - Perú. 2010.
9. **Lujano LE.** Pronostico de caudales medios mensuales del rio llave utilizando modelos de Redes Neuronales Artificiales. Tesis de Pregrado Universidad Nacional del Altiplano. Puno - Perú. 2011.
10. **Maier HR, Dandy GC.** The use of artificial neural networks for de predicction of water quality parameters. Water resources Research.1996.
11. **Masters T.** Practical neural networks recipes in C++. London: Academic Press. 1993.
12. **Negri AJ, Xu L, Adler RF.** A TRMM-Calibrated infrared rainfall algorithm applied over Brazil. Journal of Geophysical Research; Brazil. 2002
13. **Ritter A, Muñoz R.** Capacidad de predicción de Modelos Aplicados a la ZNS: Herramienta informática para la adecuada evaluación de ajuste con significancia estadística. Estudio de la Zona no saturada del suelo. Volumen X.
14. **Rosenblatt F.** The perceptron: A probabilistic model for information storage and organization in the brain. Psychological Review.1958
15. **Rumelhart DE, Hinton GE, Williams R J.** Learning internal representations by error propagation. En: D. E. Rumelhart DE, McClland JL. (Eds.). Parallel distributed processing. Cambridge, MA: MIT Press. 1986.
16. **Tang H, Tan KC, Yi Z.** Neural Networks: Computational Models and Applications. Series: Studies in Computational Intelligence. Springer. 2007.