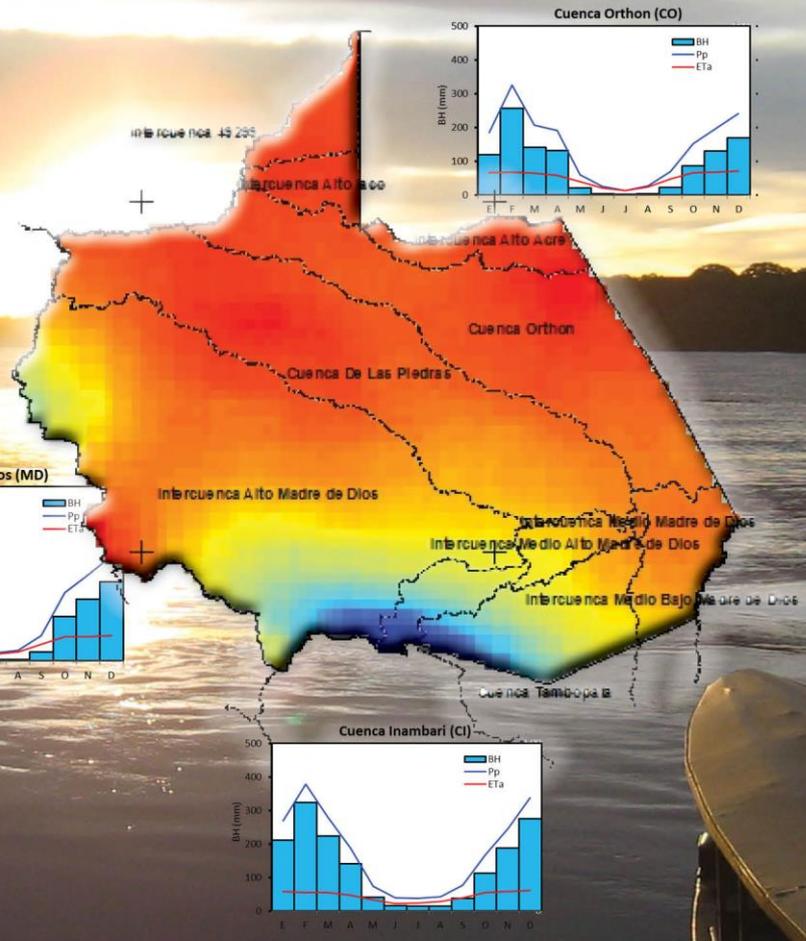


CARACTERIZACIÓN HIDROLÓGICA DE LA REGIÓN MADRE DE DIOS



CARACTERIZACIÓN HIDROLÓGICA DE LA REGIÓN MADRE DE DIOS



DIRECTORIO

Dr. Ken Takahashi Guevara

Presidente Ejecutivo del SENAMHI

Ing. Oscar Felipe Obando

Director de la Dirección de Hidrología del SENAMHI

Mg. Sc. Julia Acuña Azarte

Subdirectora de Estudios e Investigaciones Hidrológicas del
SENAMHI

REVISOR DEL ESTUDIO

Mg. Sc. Julia Acuña Azarte

Subdirectora de Estudios e Investigaciones Hidrológicas del
SENAMHI

RESPONSABLE DEL ESTUDIO

Bach. Darwin Santos Villar

Especialista en Hidrología del SENAMHI

DISEÑO, DIAGRAMACIÓN Y EDICIÓN

Miriam Casaverde Riveros

Especialista en Hidrología VI del SENAMHI

Lima - Perú

Diciembre - 2017

Citar como:

Santos, D. Caracterización hidrológica de la región Madre de Dios. Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI). Dirección de Hidrología. Diciembre, 2017.

INDICE

1. INTRODUCCIÓN	1
1.1. ANTECEDENTES	1
1.2. JUSTIFICACIÓN	1
1.3. OBJETIVOS	2
1.3.1. Objetivo general.....	2
1.3.2. Objetivos específicos.....	2
2. MARCO TEÓRICO	2
2.1. SENSORAMIENTO REMOTO	2
2.2. PRODUCTOS SATELITALES DE ESTIMACIÓN DE PRECIPITACIÓN	3
2.2.1 Satélite - TRMM.....	3
2.2.2 Precipitation Estimation from Remote Sensing Information using Artificial Neural Network – PERSIANN.....	8
2.2.3 Climate Hazards Group InfraRed Precipitation with Station data (CHIRPS).....	10
2.3. ESTADÍSTICA ESPACIAL	11
2.4. GEOESTADÍSTICA	12
2.5. MÉTODOS DE INTERPOLACIÓN	12
2.5.1. Técnicas de interpolación determinísticas exactas.....	12
2.5.2. Técnicas geoestadística.....	13
3. ZONA DE ESTUDIO	16
3.1. LOCALIZACIÓN Y CARACTERÍSTICAS GENERALES	16
3.2. CLIMATOLOGÍA	16
3.3. HIDROGRAFÍA	17
4. MATERIALES Y METODOS	19
4.1. DATOS	19
4.1.1 Precipitación.....	19
4.1.2 Temperatura.....	20
4.1.3 Datos satelitales de precipitación.....	21
4.2. MÉTODO	21
4.2.1. Métodos geoestadísticos.....	21
4.2.2. Regresión - kriging.....	21
4.2.3. Validación cruzada.....	23
4.2.4. Evapotranspiración potencial.....	23
4.2.5. Modelo de balance hídrico para estimar escurrimiento.....	24
5. RESULTADOS Y DISCUSIÓN	25
5.1. PRECIPITACIÓN	25
5.2. EVAPOTRANSPIRACIÓN POTENCIAL	26
5.3. ESCURRIMIENTO SUPERFICIAL	28
6. CONCLUSIONES	29
7. BIBLIOGRAFÍA	30
8. ANEXO	31

LISTA DE FIGURAS

Figura 2 - 1. Componentes del proceso de teledetección.....	3
Figura 2 - 2. Órbita y cobertura del TRMM	3
Figura 2 - 3. Representación esquemática del satélite TRMM y de los sensores que tienen a bordo ...	5
Figura 2 - 4. Etapas de elaboración de los sistemas “research” del TMPA	6
Figura 2 - 5. Estimación de lluvia mediante el sistema PERSIANN. Información de los satélites GEO y LEO	9
Figura 2 - 6. Extracción de información, clasificación y estimación de lluvia del algoritmo PERSIANN-CCS	10
Figura 2 - 7. Proceso y validación del producto CHIRPS. (a) producción y aplicación del esquema CHIRPS.....	11
Figura 3 - 1. Subcuencas que conforman la cuenca de la Región Madre de Dios.....	18
Figura 4 - 1. Flujograma del proceso metodológico.....	19
Figura 5 - 1. Precipitación media areal para el año promedio (1981-2015) de las cuencas de la región de Madre de Dios.....	25
Figura 5 - 2. Evapotranspiración potencial media areal para el año promedio (1981-2015) de las cuencas de la región de Madre de Dios.....	27
Figura 5 - 3. Esgurrimiento superficial medio areal para el año promedio (1981-2015) de las cuencas de la región de Madre de Dios. BH=esgurrimiento superficial (mm), P=Precipitación (mm), Eta=Evapotranspiración actual (mm).....	28
Figura 8 - 1. Mapa de precipitación media areal para el año promedio (1981-2015) de las cuencas de la región de Madre de Dios.....	32
Figura 8 - 2. Mapa de evapotranspiración potencial media areal para el año promedio (1981-2015) de las cuencas de la región de Madre de Dios	33
Figura 8 - 3. Mapa de esgurrimiento superficial para el año promedio (1981-2015) de las cuencas de la región de Madre de Dios.....	34
Figura 8 - 4. Mapa de precipitación, evapotranspiración potencial, actual y esgurrimiento superficial medio anual para el año promedio (1981-2015).....	35

LISTA DE TABLAS

Tabla 1: Productos de precipitación del TMPA.	8
Tabla 2: Tipos de predictores Kriging y sus propiedades.	14
Tabla 3: Precipitación del ciclo anual promedio (1981-2015) en las cuencas de la región.....	26
Tabla 4: Evapotranspiración potencial para el año promedio (1981-2015) en las cuencas de la región Madre de Dios	27
Tabla 5: Esgurrimiento superficial para el año promedio (1981-2015) en las cuencas de la región Madre de Dios.	29

1. INTRODUCCIÓN

1.1. ANTECEDENTES

En la actualidad, con el avance de las tecnologías ha hecho posible la disponibilidad de datos espaciales tales como los modelos digitales de elevación (Carpenter & Georgakakos, 2006.). Así, como el reciente desarrollo en los productos de precipitación basado en satélites, que han incrementado su uso como entrada en los modelos hidrológicos distribuidos (Stisen and Sandholt, 2010). Estos datos son muy valiosos en países en desarrollo o en zonas remotas, donde los datos pluviométricos son escasos o de mala calidad (Hughes, 2006). El uso de la información basada en satélites para mejorar las estimaciones de la variabilidad espacial de lluvia se ha informado ampliamente (Hsu et al., 1999; Sorooshian et al., 2000; Grimes y Diop, 2003). Sin embargo, los datos de satélite tienen sesgos y errores aleatorios que son causados por diversos factores como la frecuencia de muestreo, el o uniforme campo de vista de los sensores, las incertidumbres en los algoritmos de estimación de precipitación (Nair et al., 2009). Por eso, es fundamental validar estos productos de satélite con estaciones convencionales para cuantificar la utilidad directa de los productos (Nair et al., 2009).

1.2. JUSTIFICACIÓN

Para una adecuada gestión integral de los recursos hídricos es necesario conocer la variabilidad espacio temporal de los cursos de agua, y los caudales necesarios para el adecuado equilibrio dinámico de los ecosistemas; con la finalidad de apoyar en la toma de decisiones y planificación. Sin embargo, en la mayoría de las regiones de los países en desarrollo, la información disponible acerca de sus recursos hídricos es muy limitada y tienen una base de datos muy escasa (Salzmann et al., 2009). Por lo cual, el balance hídrico distribuido se presenta como una herramienta importante para poder estimar los caudales en cuencas sin información. No obstante una de las mayores limitaciones en la simulación de caudales, es la falta de datos climáticos, principalmente por la falta de estaciones pluviométricas in situ. Este es el caso de la cuenca amazónica (Espinoza et al., 2009), específicamente la cuenca del río Madre de Dios. Una opción a la solución de este problema, es el uso de lluvia estimada por sensoramiento remoto, ya que estos se encuentran uniformemente distribuidos.

El Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI) viene realizando trabajos para explicar la variabilidad espacial y temporal de las variables meteorológicas en el territorio peruano, a partir de información observada y datos de satélite, basado en técnicas estadísticas ha generado mapas a una resolución espacial de 5 km y una resolución temporal de un mes. En tal sentido, el producto PISCO (peruvian interpolation of the SENAMHI's climatological and hydrological data observed) estima las variaciones espaciales y temporales de la precipitación (obtenido mediante técnicas geoestadística), la temperatura mínima y máxima (mediante regresiones múltiples).

En el presente estudio se describen de manera espacial las variables de precipitación, evapotranspiración potencial y escorrentía mensual dentro de la región Madre de Dios. En tal sentido el objetivo del presente informe es describir la variabilidad espacio temporal de la precipitación, evapotranspiración potencial y la escorrentía en las cuencas ubicada en la región Madre de Dios a

partir de los mapas de precipitación y temperaturas elaborados por el SENAMHI, de resolución espacial de 5 km.

1.3. OBJETIVOS

1.3.1. Objetivo general

- Realizar la caracterización hidrológica de las cuencas hidrográficas perteneciente a la Región Madre de Dios

1.3.2. Objetivos específicos

- Describir la variabilidad espacio temporal de la precipitación, evapotranspiración y escorrentía mensual y anual de las cuencas ubicadas en la región Madre de Dios.
- Elaborar mapas de Precipitación, Evapotranspiración y Escurrimiento mensual y anual para la región Madre de Dios, para el periodo 1981-2015

2. MARCO TEÓRICO

2.1. SENSORAMIENTO REMOTO

Sensoramiento Remoto o Teledetección es la ciencia y el arte de obtener información de un objeto, área o fenómeno, a través del análisis de datos adquiridos mediante un dispositivo, el cual no está en contacto directo con el objeto, área o fenómeno que se está investigando (Thomas M. Lillesand, Ralph W. Kiefer, 1989).

La obtención de los datos se realiza a través del uso de instrumentos llamados sensores, capaces de ver o captar las relaciones espectrales y espaciales de objetos y materiales observables a una distancia considerable de aquellos.

Hay muchas aplicaciones en la que los sensores pueden usarse y proveer de información detallada ya sea sobre materiales y/o objetos en la superficie terrestre. Una de ellas es la generación de modelos digitales de terreno a partir de técnicas estereoscópicas e interferométricas principalmente. El proceso de teledetección se puede apreciar en la Figura 2-1.

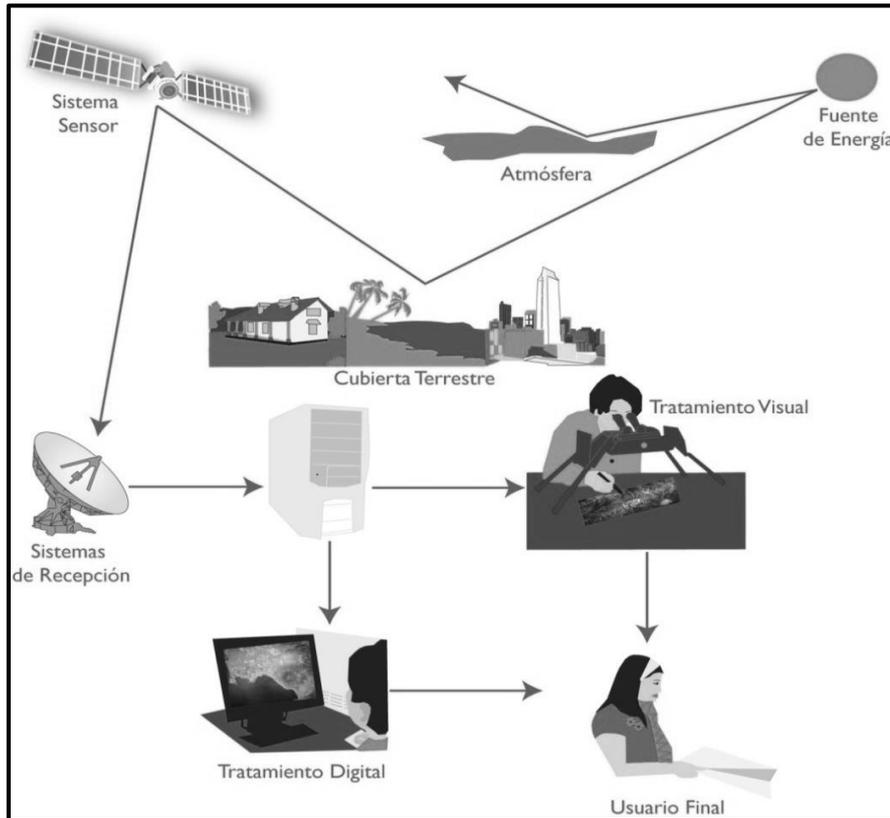


Figura 2 - 1. Componentes del proceso de teledetección

2.2. PRODUCTOS SATELITALES DE ESTIMACIÓN DE PRECIPITACIÓN

2.2.1 Satélite - TRMM

El satélite TRMM (por sus siglas en inglés de: *Tropical Rainfall Measuring Mission*) fue lanzado al espacio el 27 de noviembre de 1997, con el objetivo específico de monitorear y estudiar las precipitaciones en las regiones tropicales y subtropicales (donde se producen 2/3 del total de la precipitación mundial) (Kummerow et al., 2000). El satélite TRMM constituye la misión conjunta (japonesa-estadounidense) entre JAXA (*Japan Aerospace and Exploration Agency*) y la NASA (*National Aeronautics and Space Administration*).

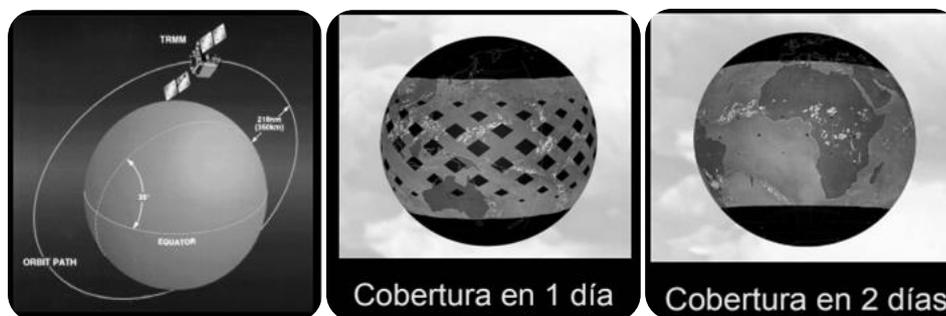


Figura 2 - 2. Órbita y cobertura del TRMM

La órbita del satélite TRMM es circular a una altitud de 350 Km (403 km a partir del 2001) y con una inclinación de 35° respecto al ecuador. Realiza un período de 92,5 minutos para completar una órbita (Aprox. realiza 16 órbitas por día), con el fin de obtener una resolución espacial alta y capturar la variación diurna de la lluvia tropical, como se puede apreciar en la Figura 2-2.

Instrumentos del TRMM

Son:

- **Radar de precipitación (Precipitation Radar, PR)**
Primer instrumento diseñado para proporcionar mapas tridimensionales de la estructura de las tormentas; información sobre la intensidad y distribución de la lluvia, el tipo de lluvia y la profundidad de las tormentas. Presenta una resolución horizontal de 5 Km, ancho de la franja: 247 Km. Además posee la capacidad de proporcionar perfiles verticales de la lluvia y nieve desde la superficie hasta una altura de aproximadamente 20 Km. Así mismo es capaz de detectar lluvia muy ligera de hasta 0,7 mm/hr.
- **Radiómetro multicanal de microondas pasivas (Microwave Imager, TMI)**
Es un sensor de microondas pasivo, que proporciona información cuantitativa de la precipitación sobre una amplia franja de 878 Km sobre la superficie. Cuantifica el vapor de agua, el agua en las nubes, y la intensidad de lluvia en la atmosfera. Mide la intensidad de la radiación en cinco frecuencias separadas: 10,7; 19,4; 21,3; 37 y 85,5 GHz, que lo hace mejor a los instrumentos predecesores.
- **Sensores de radiación visible e infrarroja (Visible/Infrared radiometer, VIRS)**
Indicador indirecto de la lluvia. Empata las mediciones del TRMM con otras mediciones rutinarias hechas por los satélites de órbita polar (POES) y de órbita geoestacionarios (GOES). Detecta la radiación proveniente de la Tierra en cinco bandas espectrales que van del visible al infrarrojo (0,63 a 12 micrómetros). La intensidad de la radiación se usa para determinar la luminosidad (visible e IR cercano) o la temperatura (IR) de la fuente. Si el cielo está despejado, la T corresponderá a la de la superficie terrestre; si hay nubes la T será la del tope de las nubes. Como las nubes más frías ocurren a mayores alturas, las temperaturas estimadas indican su altura y las nubes más altas pueden asociarse con la presencia de lluvia.
- **Sistema de energía radiante de la Tierra y de las nubes (Clouds and the Earth's Radiant Energy Sensor, CERES)**
CERES mide la energía al tope de la atmósfera, así como estima los niveles de energía dentro de la atmósfera y de la superficie terrestre. Usando información de un Banco de imágenes de nubes de altísima resolución, de los mismos patrones de formas, CERES determina las propiedades nubosas: cantidad de nubosidad, altitud, espesor, tamaño de partículas de las nubes. Todas estas mediciones son críticas para el entendimiento del sistema total climático y para mejorar los modelos predictivos de clima.

- **Sensor de relámpagos (Lightning Imaging Sensor, LIS)**
El LIS es un complejo instrumental para detectar y localizar relámpagos en las zonas de abordaje del TRMM. El detector es una compacta combinación de elementos ópticos y electrónicos incluyendo un detector de brillos de estrellas capaz de localizar y detectar relámpagos en nubes de tormenta individuales. El campo de visión del LIS permite poder observar un mismo punto terrestre o una nube por 80 s, suficiente tiempo para estimar la relación de flashes, que informa al investigador si una tormenta crece o decae.

Los sensores del TRMM son mostrados en la siguiente Figura 2-3.

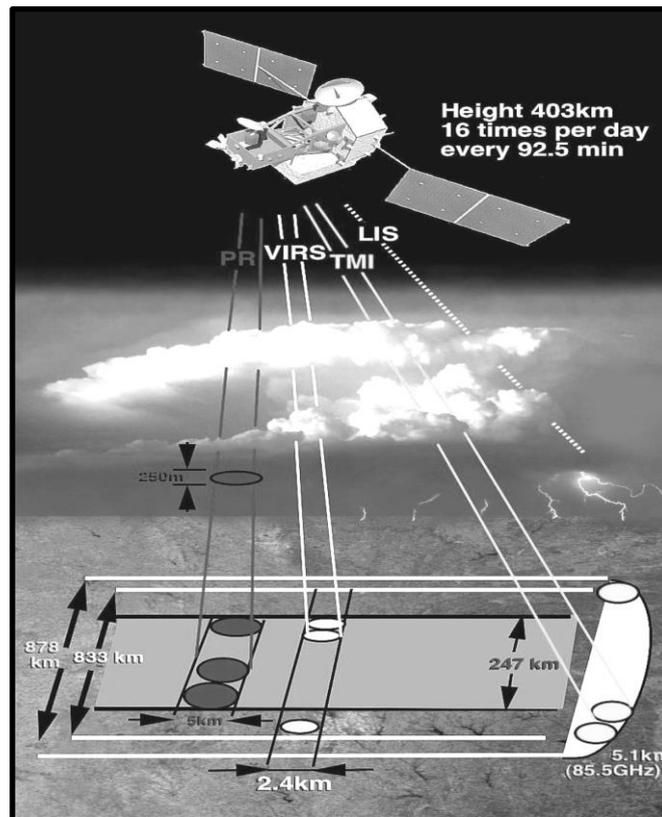


Figura 2 - 3. Representación esquemática del satélite TRMM y de los sensores que tienen a bordo

Fuente: https://trmm.gsfc.nasa.gov/overview_dir/background.html

EL TMPA

Como los algoritmos han mejorado a lo largo de los años, se han lanzado muchos satélites y se han introducidos nuevos métodos para medir la precipitación. Los más importantes son los productos del Análisis de Precipitación Multisatélite del TRMM (TMPA), basada en la combinación de estimación de la precipitación de múltiples satélites (Huffman et al. 2007).

Los productos TMPA se basan en dos informaciones principales. La primera fuente de datos es imágenes de microondas obtenidos por los satélites de órbita polar y otras imágenes que están en la banda infrarroja (longitud de onda de cerca de $10,7 \mu\text{m}$) obtenida por los sensores a bordo de satélites geostacionarios. Además de considerar, correcciones de estaciones

terrenas en la base de datos GPCP (Global Project Climatological Precipitation) y CAMS (Climate Assessment and Monitoring System). Los sensores de microondas pasivos utilizados por TMPA son:

- SSM / I (Sensor espacial Microwave / Imager), AMSR -E (Advanced Microwave Scanning Radiometer). Del satélite AQUA,
- TMI (TRMM Microwave Imager) del satélite TRMM,
- AMSU (Advanced Microwave Sounding Unidad) NOAA,
- MHS (Microondas Sounders de humedad) de la NOAA.

Todos ellos se convierten en la estimación de las precipitaciones TSDI (TRMM Science Data and Information System) con la versión del algoritmo GPROF (Kummerow et al., 1996). En caso de lluvia la estimación AMSU, es convertido por NESDIS (National Environmental Satellite Data and Information Service) con el algoritmo propuesto por (Zhao & Weng et al. (2002) con algunas modificaciones (Huffman et al 2007; Vila et al. 2007).

Los productos finales "research" del TMPA se nombran 3B43 y 3B42, y están elaborados en cuatro etapas que se indican a continuación y que se muestran en la Figura 2-4.

TRMM Multisatellite Precipitation Analysis (TMPA)

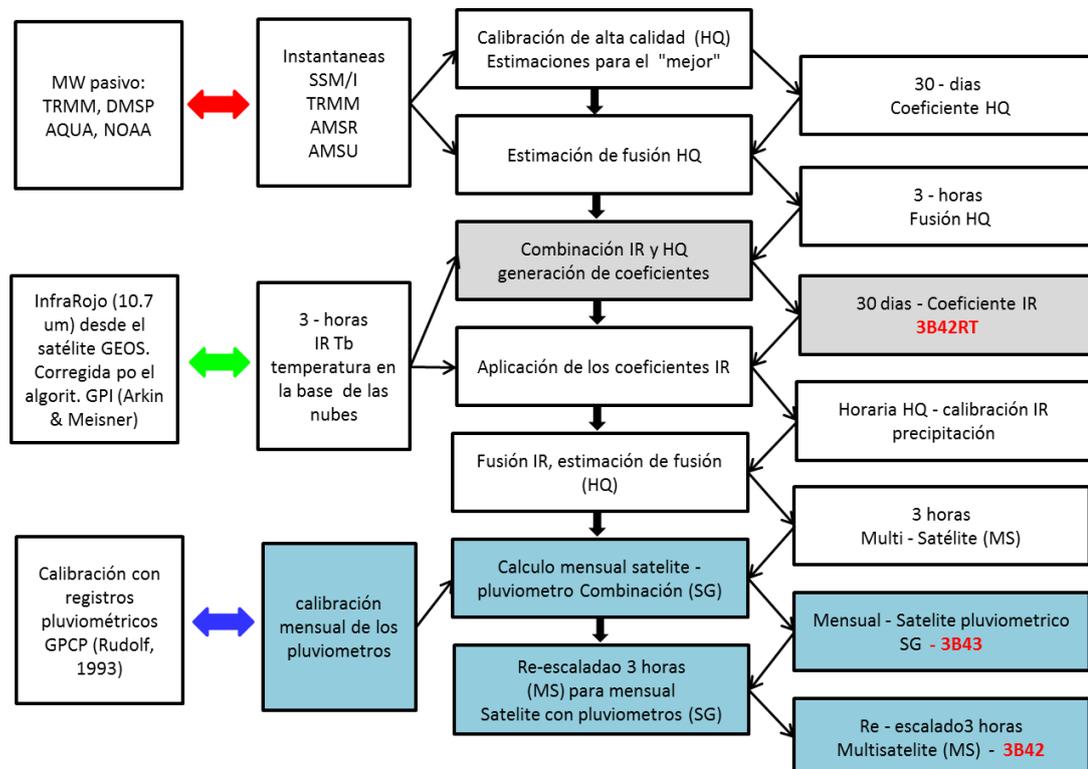


Figura 2 - 4. Etapas de elaboración de los sistemas "research" del TMPA

Fuente: Huffman et al., 2007

Se calculan estimaciones de precipitación de microondas de todas las fuentes de sensores satelitales. Estas estimaciones se ajustan a las lluvias estimadas junto con TMI y PR del satélite TRMM. El producto final de esta etapa de precipitación se estima en la escala espacial de $0,25^{\circ} \times 0,25^{\circ}$.

Las tasas de precipitación se calculan a partir de las temperaturas de brillo por CPC - IR y se combinan con la precipitación estimada a partir de la estimación de las microondas de la etapa anterior. El producto final de este paso es estimar la lluvia IR-microonda cada 3 horas y a la escala espacial de $0,25^{\circ} \times 0,25^{\circ}$.

En esta etapa se fusionan las estimaciones de microondas (primera etapa) e IR- microondas (segunda etapa). El resultado de esta combinación es poblar la estimación basada en los campos de microondas y en áreas donde carecen de información (fallas) se completan con las estimaciones de IR-microondas. El producto final de esta etapa es un producto resultante de la combinación de IR-microondas y microondas a una escala espacial de $0,25 \times 0,25^{\circ}$ cada 3 horas.

Por último, una base de datos pluviométricos se integra a todo este proceso. Las estimaciones de la tercera etapa (fusionado microondas y IR- microondas) en 3 horas se agregan a un calendario mensual para la creación del producto multisatélite (MS). El producto MS y las estaciones de pluviómetros (GPCP) se combinan (Huffman et al., 1997) para crear precipitación mensual SG resultando el producto 3B43. El siguiente paso es generar un campo en la relación SG/MS sobre píxeles de $0,25 \times 0,25^{\circ}$ y re-escalarlo cada 3 horas produciendo el producto 3B42 versión 6, el algoritmo se describe con más detalle (Huffman et al., 1997).

Las cuatro etapas anteriores son los pasos de la estimación de lluvia para los productos de 3 horas (3B42) y para la precipitación mensual (3B43). La gran ventaja es que el algoritmo proporciona soluciones en alta resolución cubriendo de 50° S a 50° N . Por otro lado, el algoritmo es complejo y la cantidad de datos necesarios para generar el producto toma tiempo en su proceso, de forma que los datos no son disponibles casi inmediatamente. Para llenar este vacío se elaboró un producto alternativo, siendo experimental y que está disponible casi en tiempo real llamado 3B42RT (Huffman et al., 1997).

El producto 3B42RT es experimental a escala temporal de 3 horas y a escala espacial de $0,25^{\circ}$. La composición de este producto sigue los pasos de la estimación del producto "research", con la diferencia de que las calibraciones realizados para la estimación de la precipitación por microondas sólo se hace con TMI y no con el PR porque PR no está disponible en tiempo real (Huffman et al., 2007, Vila et al., 2009). Además de que el producto 3B42RT no considera pluviómetros para su corrección (la cuarta etapa no se tiene en cuenta).

Los datos de los productos TMPA están disponibles como archivos que se pueden acceder a través de Internet y contiene una serie dimensionada de lluvia de 1440×440 píxeles para cada escala de tiempo de 3 horas (o mensual, según sea el caso) la escala espacial es de $0,25^{\circ} \times 0,25^{\circ}$. La Tabla 1 muestra los productos de precipitaciones TMPA, el 3B42 está disponible desde el 1 de enero de 1998. Los datos del producto 3B42RT están disponibles desde el 1 de

octubre de 2008 en la página web de TOVAS <http://disc2.nascom.nasa.gov/Giovanni/tovas/>, para usuarios que requieren precipitación diaria se encuentra el 3B42RT derived, productos 3B40RT (HQ) y 3B41RT son estimaciones de lluvia basadas en las imágenes de microondas y rayos infrarrojos, respectivamente.

Tabla 1: Productos de precipitación del TMPA.

Producto	Descripción	Data Inicial
3B42	Lluvia cada 3 horas con combinación de múltiples fuentes de sensores de satélites	Ene-98
3B42 derived	Diaria acumulado de 0 UTC a 24UTC	Ene-98
3B43	Mensual con combinación de otras fuentes de sensores	Ene-98
3B42RT	Producto experimental cada 3horas	Oct-08
3B42RT derived	Producto experimental lluvia acumulada 0 UTC a 24UTC	Oct-08
3B40RT (HQ)	Producto experimental con base en microondas intermedia de 3-hr 0,25°x0,25°	Oct-08
3B41RT	Producto experimental con base en infrarrojo IR de 3 horas cada 0,25°x0,25°	Oct-08

Fuente: TRMM (2010), <http://disc2.nascom.nasa.gov/Giovanni/tovas/> (2011)

2.2.2 Precipitation Estimation from Remote Sensing Information using Artificial Neural Network – PERSIANN

El desarrollo de la estimación de precipitación desde información de satélite usando redes neuronales artificiales está basada en tasas instantáneas de precipitación de los sensores de microonda para ajustar la función de mapeo de la imagen infrarrojo (IR) del satélite GEO y tasa de lluvia. Las características de entrada de PERSIANN son extraídas desde la textura de la imagen local de onda larga de IR (10,2-11,2 μm) de GEO satélite. La función de mapeo de ANN usando onda larga (10,2-11,2 μm) IR para el mapeo de la lluvia es implementada por:

1. La extracción local de la textura de la imagen, en términos de calcular la media y varianza del brillo de temperatura del IR cercano.
2. Clasificación de la característica extraída.
3. Mapeo multivariado de textura de clasificación para la tasa de lluvia superficial.

Una característica de entrenamiento adaptativo facilita la actualización de los parámetros de las redes siempre que las estimaciones independientes de lluvias están disponibles (Hsu et al., 1997; Sorooshian et al., 2000).

Los parámetros de PERSIANN se actualizan constantemente cuando las precipitaciones basadas en PMW están disponibles (Ferraro y Marks, 1995; Hsu et al, 1997; Janowiak et al.

2001). El algoritmo PERSIANN estima intensidad de lluvia en cada pixel de $0,25^\circ \times 0,25^\circ$ cada 30 minutos. La precipitación estimada se integra a diferentes escalas espaciales y temporales, tales como: de seis horas, diarias, mensuales, etc.

En la operación de PERSIANN, dos algoritmos se ejecutan en PERSIANN en paralelo: uno se ejecuta en el modo de simulación y el otro en el modo de actualización. El modo simulación genera la intensidad de lluvia en la superficie de resolución $0,25^\circ \times 0,25^\circ$ en cada 30 minutos de las imágenes infrarrojas de satélite GEO, mientras que el método de actualización continuamente ajusta la función de asignación de parámetros PERSIANN basado en el error de ajuste de cualquier pixel para todo PMW de estimación de lluvia instantánea disponible. El modo de simulación genera la intensidad de lluvia regular, y la el modo actualización mejora la calidad del producto. La precisión del producto final, sin embargo, depende muchos factores como: la eficacia de la función de detección y el sistema de clasificación. Imágenes IR son proporcionadas por los satélites GEO, tales como GOES-8, el GOES-10, GMS-5, y METEOSAT-6 y 7 (Janowiak et al., 2001), mientras que la precipitación PMW se calcula a partir de la información proporcionada por los satélites TRMM, NOAA-15, -16, -17, DMSP F-13, F-14 y F-15 (Ferraro y Marks, 1995; Kummerow et al., 1998) que se utiliza para entrenar a los parámetros de asignación de PERSIANN. La descripción de operación de PERSIANN se puede apreciar en la Figura 2-5.

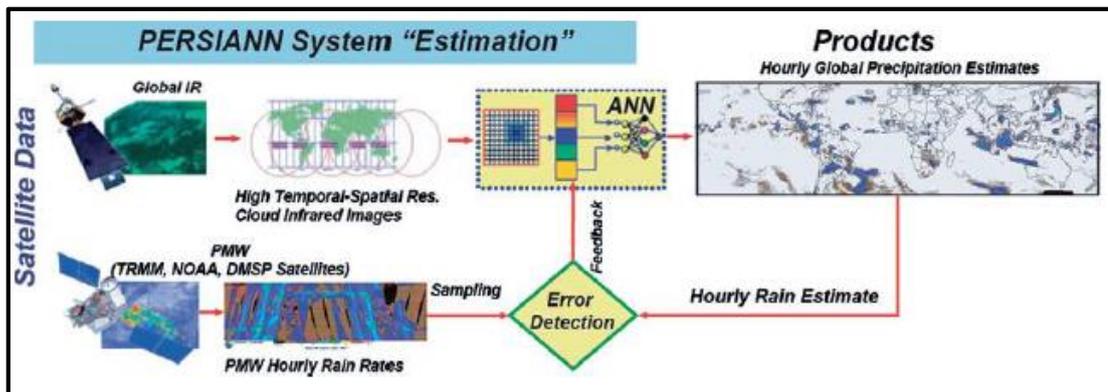


Figura 2 - 5. Estimación de lluvia mediante el sistema PERSIANN. Información de los satélites GEO y LEO
Fuente: Ferrado y Marks, 1995; Kummerow et al., 1998

PERSIANN Cloud Classification System (CCS)

Recientemente, el CHRIS_UCI desarrolló una nueva versión del PERSIANN, el PERSIANN-CCS "PERSIANN-Cloud Clasificación System". Que introduce la categorización de las nubes en base a la altura en el tope de la nube, geometría y textura, estimada a partir de imágenes de satélite para obtener intensidades de lluvia de diferentes nubes y resolución espacial de 0.04° (Hong et al., 2004; Hong et al., 2007; Kuo-lin et al., 2010).

PERSIANN-CCS consiste de cuatro pasos importantes:

1. Segmentación de imágenes de nubes IR.
2. Extracción de características desde parches de nubes IR

3. Clasificación de elementos de parche,
4. Estimación de la precipitación.

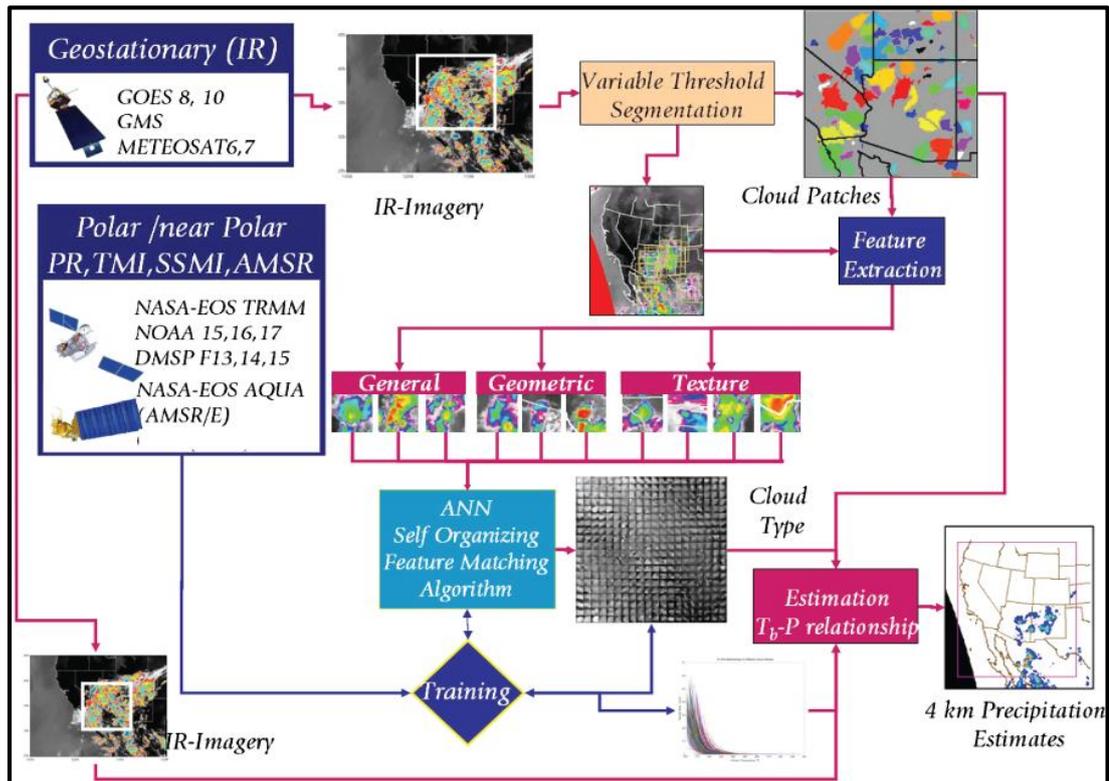


Figura 2 - 6. Extracción de información, clasificación y estimación de lluvia del algoritmo PERSIANN-CCS
Fuente: (Hong et al., 2004; Hong et al., 2007; Kuo-lin et al., 2010).

2.2.3 Climate Hazards Group InfraRed Precipitation with Station data (CHIRPS)

Una nueva cuasi-global (50 ° S-50 ° N), de alta resolución (0,05 °), de registros diarios y de datos de precipitación mensual. CHIRPS fue desarrollado para apoyar a la Agencia de Estados Unidos para sistemas de alerta temprana. Sobre la base de experiencias exitosas de productos de precipitación como el infrarrojo termal (TIR) como la NOAA's, CHIRPS usa la información de la Tropical Rainfall Measuring Multi-Satellite precipitation (TRMM) versión 7 (TMPA 3B42 v7) para calibrar la duración de las lluvias de nubes frías. También, usa el enfoque de interpolación de datos de estaciones, CHIRPS usa un enfoque de "interpolación inteligente", trabajando con anomalías desde climatologías de alta resolución. CHIRPS incorpora datos de estaciones en dos fases del proceso, produciendo dos productos únicos. Por lo tanto, CHIRPS se ubica entre los conjuntos de datos interpolados y calibrados como el GPCC y RFE2.

En la actualidad, y a escala global, existe un importante vacío en los tipos de datos grillados de precipitación. Existe base de datos con un periodo largo de registros, como GPCC y CRU, y existen precipitaciones estimadas solo con información de satélite, como TMPA 3B42 RT, centro de predicción climática MORPHing Technique (CMORPH), o estimaciones de precipitación desde sensores remotos usando redes neuronales artificiales (PERSIANN), o información de re-análisis, como Coupled Forecast System (CFS) o the European Centre for Medium-range Weather Forecasts (ECMWF).

La Figura 2-7, muestra el esquema general de los datos CHIRPS, el proceso de los datos CHIRPS contienen tres importantes componentes:

- Datos climatológicos (CHPclim).
- Datos solo del satélite CHIRP
- Datos de satélite corregidos con datos observados CHIRPS.

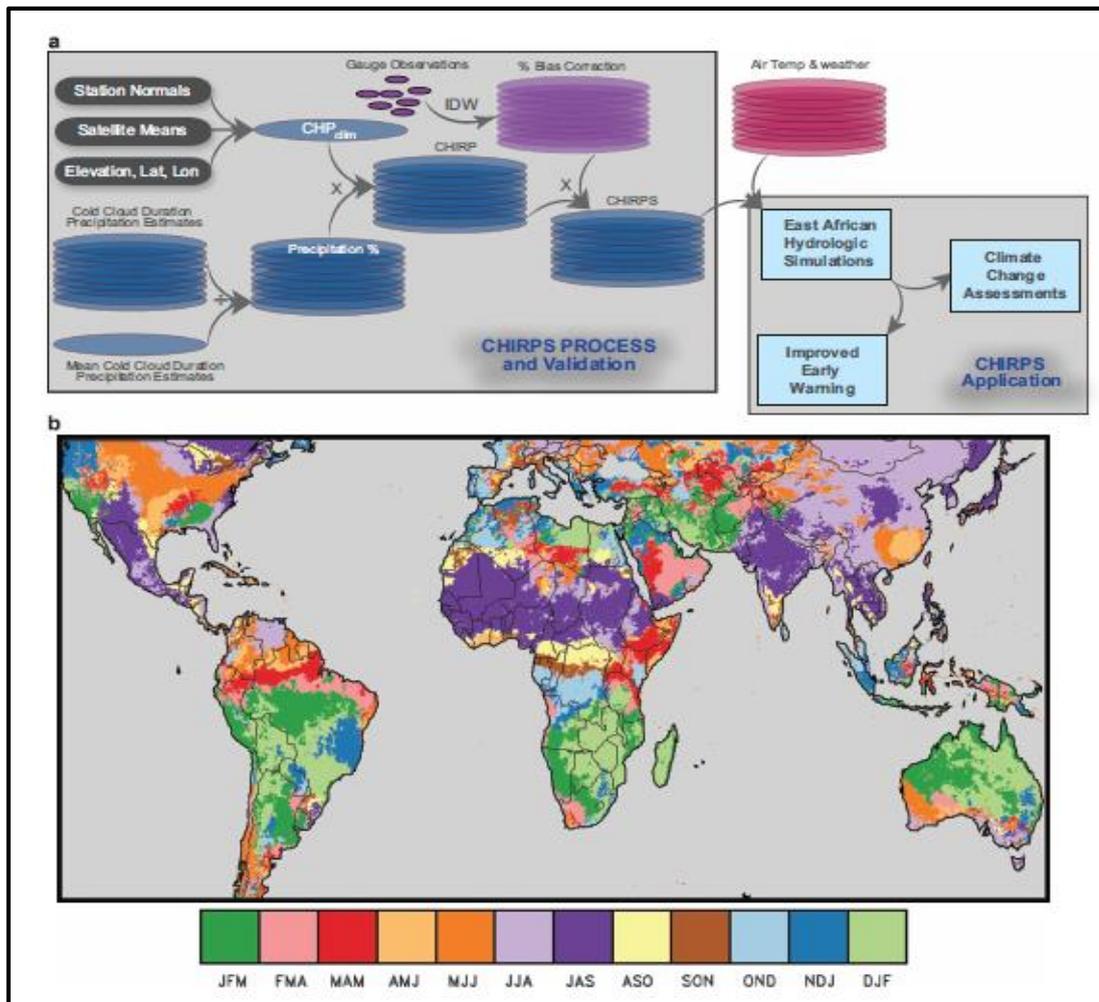


Figura 2 - 7. Proceso y validación del producto CHIRPS. (a) producción y aplicación del esquema CHIRPS
(b) Mapa de meses más húmedos cada tres meses basado en CHPclim

2.3. ESTADÍSTICA ESPACIAL

Estadística espacial es la reunión de un conjunto de metodologías apropiadas para el análisis de datos que corresponden a la medición de variables aleatorias en diversos sitios (puntos del espacio o agregaciones espaciales) de una región. De manera más formal se puede decir que la estadística espacial trata con el análisis de realizaciones de un proceso estocástico $\{Z(s): s \in D\}$, en el que $s \in R^d$ representa una ubicación en el espacio euclidiano d-dimensional, $Z(s)$ es una variable aleatoria en la ubicación s y s varía sobre un conjunto de índices $D \subset R^d$ (Giraldo, 2005).

2.4. GEOESTADÍSTICA

La geoestadística es una rama de la estadística que trata fenómenos espaciales. Su interés primordial es la estimación, predicción y simulación de dichos fenómenos. Esta herramienta ofrece una manera de describir la continuidad espacial, que es un rasgo distintivo esencial de muchos fenómenos naturales, y proporciona adaptaciones de las técnicas clásicas de regresión para tomar ventajas de esta continuidad. Es una aplicación de la teoría de probabilidades a la estimación estadística de variables espaciales.

La modelación espacial es la adición más reciente a la literatura estadística. Geología, ciencias del suelo, agronomía, ingeniería forestal, astronomía, o cualquier disciplina que trabaja con datos colectados en diferentes locaciones espaciales necesita desarrollar modelos que indiquen cuando hay dependencia entre las medidas de los diferentes sitios. Usualmente dicha modelación concierne con la predicción espacial, pero hay otras áreas importantes como la simulación y el diseño muestral.

Cuando el objetivo es hacer predicción, la geoestadística opera básicamente en dos etapas. La primera, es el análisis estructural, en la cual se describe la correlación entre puntos en el espacio. En la segunda fase se hace predicción en sitios de la región no muestreados por medio de la técnica kriging. Este es un proceso que calcula un promedio ponderado de las observaciones muestrales. Los pesos asignados a los valores muestrales son apropiadamente determinados por la estructura espacial de correlación establecida en la primera etapa y por la configuración de muestreo (Giraldo, 2005).

2.5. MÉTODOS DE INTERPOLACIÓN

2.5.1. Técnicas de interpolación determinísticas exactas

Moreno et al. (2007) mencionan que las técnicas de interpolación deterministas se pueden clasificar en dos grupos, en función del número de datos muestrales utilizados para estimar el valor de la variable en los puntos no muestrales. Técnicas globales que son las que tienen en cuenta todos los puntos muestrales en cualquier valor estimado (polinomio global) y las locales que solo emplean los puntos muestrales que están en la vecindad de cada punto no muestral. A su vez se diferencian entre técnicas de interpolación exactas y aproximadas cuya distinción reside en si el resultado del proceso de interpolación reproduce exactamente los valores en los puntos muestrales o lo hace sólo de manera aproximada.

Interpolación con la media ponderada por el inverso de la distancia

Moreno et al. (2007) menciona que la técnica de la "media ponderada por el inverso de la distancia", denominada en inglés inverse distance weighted (IDW), asume que las cosas que están más cerca son más parecidas que las que están más lejos. Para predecir un valor de un lugar no muestral, utilizará los valores de los lugares muestrales que haya alrededor del lugar que se va a predecir. Los valores de los lugares más próximos al que se va a predecir tendrán

más influencia y por lo tanto más peso que los que están más lejos. Este peso disminuye con la distancia. La fórmula general es:

$$Z(s_0) = \sum_{i=1}^N \lambda_i \cdot Z(s_i)$$

Donde $Z(s_0)$ es el valor que intentamos predecir para el lugar s_0 . N es el número de puntos muestrales alrededor del lugar que se va a predecir y que serán tomados en cuenta en la predicción. λ_i es el peso asignado a cada punto muestral que vamos a usar. Estos pesos decrecen con la distancia, $Z(s_i)$ es el valor observado del lugar s_i . La fórmula para determinar los pesos es:

$$\lambda_i = \frac{d_{i0}^{-p}}{\sum_{i=1}^N d_{i0}^{-p}}$$

A medida que la distancia se hace más grande, el peso es reducido por un factor p . es decir, que a medida que se incrementa la distancia entre los puntos observados y el punto calculado, el peso que tendrá un punto muestral sobre el predicho decrecerá exponencialmente, d_{i0} es la distancia entre el lugar de predicción s_0 y cada lugar muestral, s_i . Los pesos de los lugares utilizados para la predicción serán escalados de tal forma que su suma sea 1, es decir,

$$\sum_{i=1}^N \lambda_i = 1$$

El óptimo valor de p se determina haciendo mínimo el error de predicción o error cuadrático medio, que tiene la siguiente formula:

$$EMC = \sqrt{\frac{\sum_{i=1}^n (Z(s_i) - z(s_i))^2}{n}}$$

Por lo general se utiliza un valor de $p=2$ que se conoce como distancia inversa al cuadrado. Además, es importante es determinar el número de vecinos a tener en cuenta para calcular el valor predicho. Esto dependerá del tipo de datos y de la superficie que intentemos crear.

2.5.2. Técnicas geoestadística

De la teoría de la decisión se conoce que si Z_0 es una cantidad aleatoria y Z^*_0 es su predictor, entonces $L(Z_0 ; Z^*_0)$ representa la pérdida en que se incurre cuando se predice Z_0 con Z^*_0 y el mejor predictor será el que minimice $E\{L(Z_0 ; Z^*_0) / Z\}$ con $Z=\{Z_1, Z_2, \dots, Z_n\}$, es decir el predictor óptimo es el que minimice la esperanza condicional de la función de pérdida. Si $L(Z_0 ; Z^*_0) = [Z_0 - Z^*_0]^2 \rightarrow Z^*_0 = E(Z_0/Z)$. La expresión anterior indica que para encontrar el predictor óptimo se requiere conocer la distribución conjunta de la $n+1$ variables aleatorias.

a. Kriging

La palabra kriging (expresión anglosajona) procede del nombre del geólogo sudafricano D. G. Krige, cuyos trabajos en la predicción de reservas de oro, realizados en la década del cincuenta, suelen considerarse como pioneros en los métodos de interpolación espacial. Kriging encierra un conjunto de métodos de predicción espacial que se fundamentan en la minimización del error cuadrático medio de predicción. En la tabla 2 se mencionan los tipos de kriging y algunas de sus propiedades.

Tabla 2: Tipos de predictores Kriging y sus propiedades.

Tipo de Predictor	Nombre	Propiedades
Lineal	<ul style="list-style-type: none"> ▪ Simple ▪ Ordinario ▪ Universal 	<ul style="list-style-type: none"> ▪ Son óptimos si hay normalidad multivariada. ▪ Independiente de la distribución son los mejores predictores linealmente insesgados.
No Lineal	<ul style="list-style-type: none"> ▪ Indicador ▪ Probabilístico ▪ Log Normal, Trans-Gaussiano. ▪ Disyuntivo 	<ul style="list-style-type: none"> ▪ Son predictores óptimos.

b. Cokriging

Si se tienen dos variables regionalizadas $Z_{v1}(x)$ y $Z_{v2}(x)$ tomadas en sitios de la región de estudio, no necesariamente iguales, entonces el semivariograma cruzado entre ellas, se estima por:

$$\gamma_{v1v2}(h) = \frac{1}{2n_h} \sum \{Z_{v1}(x+h) - Z_{v1}(x)\} * \{Z_{v2}(x+h) - Z_{v2}(x)\}$$

Donde n_h es el número de parejas de datos que se encuentran a una distancia h .

Modelo lineal de correogionalización (MLC)

El MLC asume que todos los semivariogramas simples y cruzados pueden expresarse como una suma de modelos básicos (exponencial, esférico, gaussiano, etc.) idénticos. Para el caso de dos variables:

$$\begin{aligned} \gamma_{v1}(h) &= \alpha_0 * \gamma_0(h) + \dots + \alpha_m * \gamma_m(h) \\ \gamma_{v2}(h) &= \beta_0 * \gamma_0(h) + \dots + \beta_m * \gamma_m(h) \\ \gamma_{v1v2}(h) &= \delta_0 * \gamma_0(h) + \dots + \delta_m * \gamma_m(h) \end{aligned}$$

Donde $\gamma_{v1}(h)$ y $\gamma_{v2}(h)$ son los semivariogramas simples, $\gamma_{v1v2}(h)$ es el semivariograma cruzado. $\gamma_0(h)$, $\gamma_1(h)$, . . . , $\gamma_m(h)$ son los modelos básicos de semivariograma y α , β y δ son constantes. Matricialmente:

$$\Gamma(h) \begin{vmatrix} \gamma_{v1}(h) & \gamma_{v1v2}(h) \\ \gamma_{v1v2}(h) & \gamma_{v2}(h) \end{vmatrix} = \sum_{s=0}^m B_s * \gamma_s(h), \text{ donde}$$

$$B_s = \begin{vmatrix} \alpha_s & \delta_s \\ \delta_s & \beta_s \end{vmatrix} \quad \gamma_s(h) = \begin{vmatrix} \gamma_s(h) & 0 \\ 0 & \gamma_s(h) \end{vmatrix}$$

$\Gamma(h)$ se le conoce como matriz de correogionalización.

Predictor cokriging

El método de predicción espacial cokriging consiste en hacer predicción espacial de una variable con base en su información y en la de algunas variables auxiliares que este correlacionadas espacialmente con ella. El predictor cokriging tiene la siguiente expresión en el caso en el que se considera una sola variable auxiliar:

$$Z_{v1} * (x_0) = \sum_{i=1}^{n_1} a_i Z_{v1}(x_i) + \sum_{j=1}^{n_2} b_j Z_{v2}(x_j)$$

El lado izquierdo de la igualdad en la ecuación anterior representa la predicción de la variable de interés en el punto x_0 no muestreado $Z_{v1}(x_0)$ con $i=1, 2, \dots, n_1$, representa la variable primaria. Así mismo, $Z_{v2}(x_j)$ con $j=1, 2, \dots, n_2$, representa la variable auxiliar a_i y b_j , con $i=1, 2, \dots, n_1$ y $j=1, 2, \dots, n_2$ respectivamente, representan los pesos o ponderaciones de las observaciones de las variables primaria y auxiliar y se estiman con base en el MLC ajustado a los semivariogramas simples y cruzados. Los pesos a_i y b_j se estiman de manera análoga al proceso descrito para el método kriging ordinario, es decir estos serán los que minimizan la varianza del error de predicción sujeta a la restricción de que el predictor sea insesgado. La estimación de los parámetros se obtiene resolviendo el siguiente sistema de ecuaciones:

$$\begin{bmatrix} \gamma_{v1}(1,1) & \dots & \gamma_{v1}(n,1) & \gamma_{v1v2}(1,1) & \dots & \gamma_{v1v2}(m,l) & 1 & 0 \\ \vdots & \vdots \\ \gamma_{v1}(1,n) & \dots & \gamma_{v1}(n,n) & \gamma_{v1v2}(1,n) & \dots & \gamma_{v1v2}(m,n) & 1 & 0 \\ \gamma_{v1v2}(1,1) & \dots & \gamma_{v1v2}(n,1) & \gamma_{v2}(1,1) & \dots & \gamma_{v2}(m,l) & 0 & 1 \\ \vdots & \vdots \\ \gamma_{v1v2}(1,m) & \dots & \gamma_{v1v2}(n,m) & \gamma_{v2}(1,m) & \dots & \gamma_{v2}(m,m) & 0 & 1 \\ 1 & \dots & 1 & 0 & \dots & 0 & 0 & 0 \\ 0 & \dots & 0 & 1 & \dots & 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} a_1 \\ \vdots \\ a_n \\ b_1 \\ \vdots \\ b_m \\ \mu_1 \\ \mu_2 \end{bmatrix} = \begin{bmatrix} \gamma_{v1}(0,1) \\ \vdots \\ \gamma_{v1}(0,n) \\ \gamma_{v1v2}(0,1) \\ \vdots \\ \gamma_{v1v2}(0,m) \\ 1 \\ 0 \end{bmatrix}$$

La matriz del lado izquierdo contiene los valores de las funciones de semivarianza y de semivarianza cruzada calculadas para todas las distancias entre las parejas de puntos consideradas. Las dos últimas filas de dicha matriz son las correspondientes a la restricción de insesgamiento del predictor. a_i y b_j con $i = 1, 2, \dots, n$ y $j = 1, 2, \dots, m$, son los parámetros a estimar, μ_1 y μ_2 son los multiplicadores de Lagrange empleados para la restricción de insesgamiento y el vector del lado derecho contiene los valores de las funciones de

semivarianza y semivarianza cruzada evaluados para las distancia entre los sitios de muestreo (de ambas variables) y el sitio donde se desea hacer la predicción. Las dos últimas filas del vector están asociadas a la condición de insesgamiento. La correspondiente varianza de predicción del método cokriging se calcula como:

$$\sigma_k^2 = Cov(Z_{v1}(x_0), Z_{v1}(x_0)) + \mu_1 + \sum_{i=1}^n a_i \cdot Cov(Z_{v1}(x_i), Z_{v1}(x_0)) + \sum_{j=1}^m b_j \cdot Cov(Z_{v2}(x_j), Z_{v2}(x_0))$$

Donde μ_1 es el multiplicador de Lagrange empleado para la restricción dado por la condición de insesgamiento

$$\sum_{i=1}^n a_i = 1$$

$$Cov(Z_{vi}(x_k), Z_{vi}(x_l)) = \sigma_{vi}^2 - \gamma_{vivi}(k, l)$$

Es la función de covarianza espacial de la variable $i, i=1,2$, evaluada para la distancia entre los sitios de muestreo k, l . La ventaja del método cokriging frente al kriging radica en el hecho de que cuando la variable auxiliar está ampliamente correlacionada con la variable de interés se puede obtener una disminución en la varianza de predicción, no obstante dicha variable tenga menor densidad de muestreo. En situaciones en las que la variable objetivo tiene costos altos de muestreo se recomienda la aplicación de esta metodología.

3. ZONA DE ESTUDIO

3.1. LOCALIZACIÓN Y CARACTERÍSTICAS GENERALES

La Región Madre de Dios está ubicada al sureste del país. Su capital y ciudad más poblada es Puerto Maldonado, ubicada en la provincia de Tambopata.

Limita al norte con Ucayali y Brasil, al este con Bolivia, al sur con Puno y al oeste con Cuzco. Con 85 300 km² es el tercer departamento más extenso — por detrás de Loreto y Ucayali — y con 1,3 hab./km², el menos densamente poblado. Recibe su nombre del río Madre de Dios, de cuya cuenca son tributarios la mayor parte de los ríos de la región y sobre cuyas riberas se erige la capital departamental: Puerto Maldonado. Su territorio abarca zonas de selva alta y selva baja.

3.2. CLIMATOLOGÍA

El clima de Madre de Dios es de tipo tropical: cálido, húmedo y con precipitaciones anuales superiores a 1000 mm con una temperatura promedio de 17° C a 20° C en los meses de junio y julio y una máxima de hasta 36° C en los meses de diciembre a marzo.

El clima de Madre de Dios sufre a veces influencias de masas de aire frías, que llegan desde el sureste del continente americano, ocasionando sensibles bajas de temperatura, que hacen bajar el termómetro hasta 8° C y que son conocidos localmente con los nombres de "surazo" o "friaje".

3.3. HIDROGRAFÍA

El río Madre de Dios o río Amaru, es un largo río que pertenece a la cuenca del Amazonas y que cruza al departamento del mismo nombre con una densa red hidrográfica. Es un afluente del río Beni. Tiene una longitud aproximada de 1 150 km y es un río binacional, ya que discurre por la parte suroriental del Perú y noroccidental de Bolivia.

El río Madre de Dios nace en las estribaciones orientales de la cordillera de Vilcanota, al noreste de Cuzco. El río, conocido en este primer tramo como Alto Madre de Dios, se encamina primero en dirección norte y recorre 275 km hasta recibir por la izquierda al río Manu (356 Km), en la localidad homónima de Manú o Boca Manú. Continúa en dirección este, pasando por Puerto Tahuantinsuyo, donde recibe por la derecha al río Azul. Luego recibe también por la derecha, al río Colorado y llega a continuación a Madre de Dios, donde recibe por la izquierda al río de Los Amigos. Sigue hasta llegar a Inambari, donde recibe por la derecha al río Inambari (390 Km), un largo río que también desciende de las estribaciones orientales de los Andes Peruanos (Puno) y que es el principal afluente del río Madre de Dios. Continúa el río en dirección este y tras pasar por la pequeña localidad de Pastora, llega a las Piedras, donde recibe por la margen izquierda al río de las Piedras (640 Km). Llega inmediatamente a la ciudad de Puerto Maldonado, la capital del departamento de Madre de Dios y de la provincia de Tambopata. En Puerto Maldonado recibe por la margen derecha al río Tambopata (350 Km). A partir de este punto pasa a ser conocido como Bajo Madre de Dios, y traspasa por las pequeñas localidades de Colombia y San Francisco, abandona Perú por Puerto Pando. Entra en Bolivia llegando enseguida a la ciudad de Puerto Heath, donde recibe al homónimo río Heath (217 Km) por la margen derecha, un río que en todo su discurrir marca la frontera boliviano-peruana. Aquí el río vira en dirección SO-NE, una dirección que mantendrá en el tramo de 483 km que le restan hasta desembocar en el río Beni.

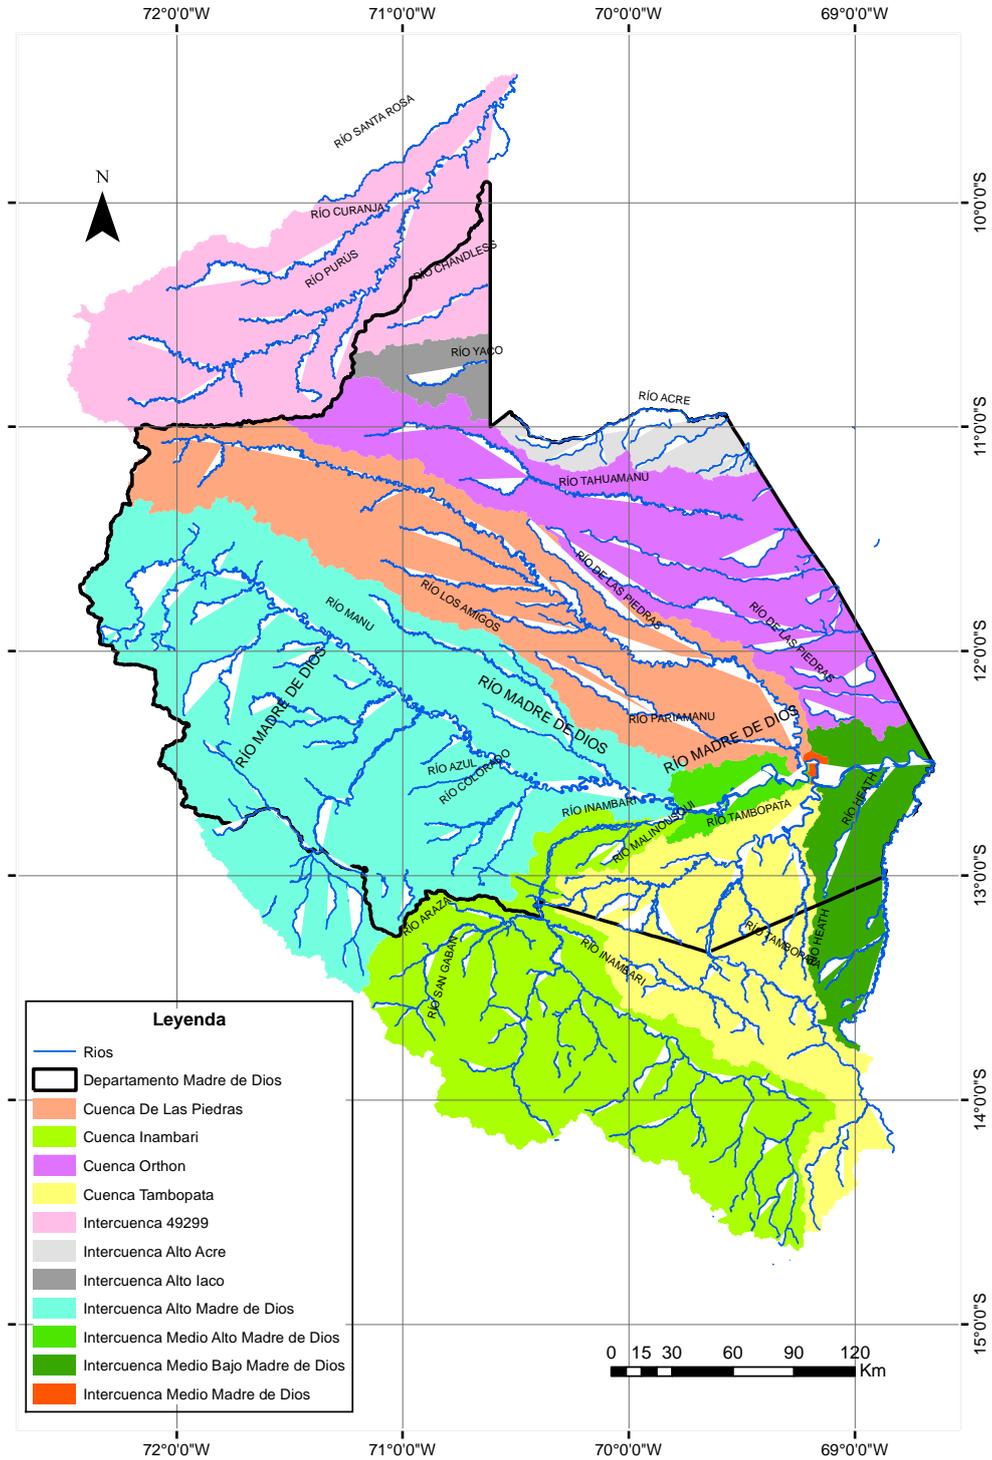


Figura 3 - 1. Subcuencas que conforman la cuenca de la Región Madre de Dios

4. MATERIALES Y METODOS

El desarrollo metodológico que sintetiza el proceso para obtener la información de escurrimiento se muestra en la Figura 4-1. Los datos de precipitación y temperatura mensual corresponden a los datos PISCO v1.0, con lo cual se generaron los mapas, a una resolución espacial de 5*5 Km. Seguidamente a partir de los mapas de temperatura se generaron los mapas de evapotranspiración potencial. Y para la generación de los mapas de escurrimiento, que se define como la cantidad de agua disponible para extracción, se obtiene a partir de la diferencia entre la precipitación y la evapotranspiración actual (obtenida mediante la expresión de Budyko). Los datos y métodos utilizados en el desarrollo del estudio se describen a continuación.

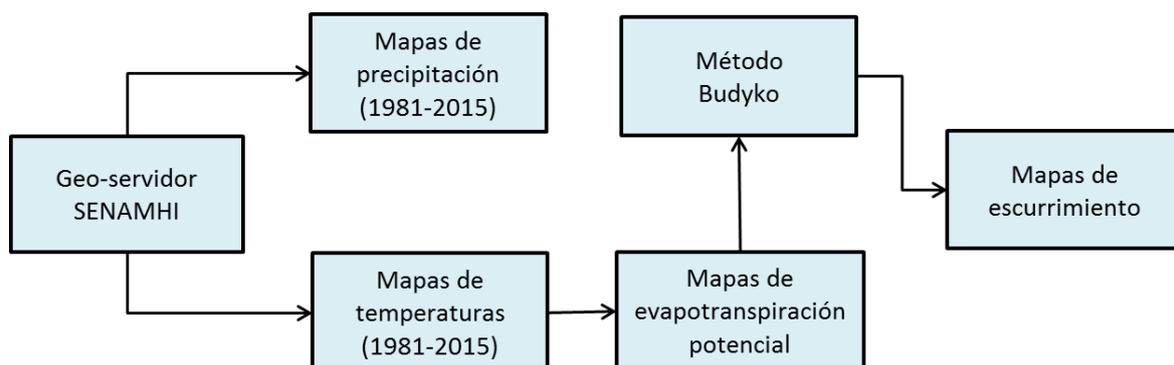


Figura 4 - 1. Flujograma del proceso metodológico.

4.1. DATOS

4.1.1 Precipitación

Los datos de precipitación utilizados en el presente estudio corresponden a los datos PISCO – precipitación v1.0, el cual es el producto, resultado de la combinación (“merging”) entre los datos de precipitación estimados por el satélite del producto CHIRPS y los datos de precipitación observada de la red de estaciones meteorológicas del SENAMHI.

Para la combinación se utilizó la técnica geoestadística Kriging con Deriva Externa (KED) por ser una técnica robusta y relativamente sencilla. En esta metodología, la variable a regionalizar es la precipitación observada (PO) y la covariable es la precipitación estimada por el satélite (producto CHIRPS), en la cual se realiza simultáneamente una regresión lineal entre PO y CHIRPS; para luego los errores residuales de esta regresión se interpolen mediante la técnica de Kriging ordinario. Finalmente el PISCO – precipitation v1.0 es el resultado de la suma espacial entre los valores estimados por la regresión y los valores residuales interpolados.

El proceso de combinación se realizó de manera independiente para cada mes de la serie histórica (Enero de 1981 hasta diciembre del 2013), debido a que se cuenta con diferente número de estaciones en cada mes (ver Fig. 1) y que el método de Kriging con Deriva Externa demanda de un modelamiento de semivariogramas residuales para establecer el semivariograma teórico (Esférico, Exponencial o Gaussiano) de mejor ajuste en cada mes.

Hasta la fecha se cuenta con una base climatológica del producto PISCO - precipitación a una resolución temporal desde 1981 hasta la actualidad. El producto PISCO - precipitación con una resolución ~ 5 Km estará próximamente disponible en la página web del SENAMHI. (<http://www.senamhi.gob.pe/?p=observacion-de-inundaciones>)

Actualmente el producto PISCO-precipitación es utilizado como datos de entrada para la elaboración de los índices de Sequía a nivel Nacional mostrados en el portal de sequías del SENAMHI (<http://www.senamhi.gob.pe/?p=sequias>).

4.1.2 Temperatura

Los datos de temperatura utilizados en el presente estudio corresponden a los datos PISCO – temperatura v1.0, el cual es un producto, resultado de una regresión multivariante, teniendo como variable explicada la temperatura mínima y máxima, como variables explicativas se tienen a la latitud, longitud, elevación, además del seno y coseno del ángulo de inclinación del terreno, obtenidas estas tres últimas variables a partir del modelo digital de elevaciones de la NASA.

Debido a que las variables explicativas no deben presentar dependencia lineal entre ellas, se utilizaron los componentes principales para obtener nuevas variables incorrelacionadas, las cuales fueron utilizadas en la generación de los modelos de regresión multivariante. Los valores observados de temperatura mínima y máxima fueron utilizados para la generar las regresiones múltiples, generándose un modelo de regresión múltiple para cada mes y año de la serie analizada.

Los errores residuales de cada regresión multivariante fueron interpolados mediante la técnica de inversa de la distancia ponderada (IDW). Finalmente el PISCO – temperatura es el resultado de la suma espacial entre los valores estimados por la regresión multivariante y los valores residuales interpolados. Para evaluar el desempeño de los modelos de regresiones multivariantes se utilizó la validación cruzada.

El proceso de combinación se realizó de manera independiente para cada mes de la serie histórica (Enero de 1981 hasta diciembre del 2014). Hasta la fecha se cuenta con una base climatológica del producto PISCO - temperatura a una resolución espacial de $0,05^\circ$ para el periodo de 1981 a la actualidad.

Actualmente el producto PISCO-temperatura es utilizado como datos de entrada para la obtención del producto PISCO-Evapotranspiración, y este en la implementación de un modelo hidrológico distribuido con fines de obtener el producto "PISCO-Escorrentía, los cuales serán mostrados en el portal de sequías del SENAMHI (<http://www.senamhi.gob.pe/serviciosclimaticos/sequia/>).

4.1.3 Datos satelitales de precipitación

En la actualidad existen diversos tipos de datos de satélite que estiman la precipitación, como ya se ha descrito en los párrafos anteriores. En el presente estudio se ha utilizado los datos del producto PISCO-precipitación, el cual fue elaborado usando datos CHIRPS, los cuales se encuentran disponibles desde:

- CHIRPS-mensuales:
ftp://ftp.chg.ucsb.edu/pub/org/chg/products/CHIRPS-2.0/global_monthly/tifs/
- CHIRPS-diarios:
ftp://ftp.chg.ucsb.edu/pub/org/chg/products/CHIRPS-2.0/global_daily/tifs/p05/
- CHIRP-mensuales:
<ftp://ftp.chg.ucsb.edu/pub/org/chg/products/CHIRP/monthly/>
- CHIRP-diarios:
<ftp://ftp.chg.ucsb.edu/pub/org/chg/products/CHIRP/daily/>
- PERSIANN:
<https://catalog.data.gov/dataset/noaa-climate-data-record-cdr-of-precipitation-estimation-from-remotely-sensed-information-using>
- CMORPH
http://www.cpc.ncep.noaa.gov/products/janowiak/cmorph_description.html

4.2. MÉTODO

4.2.1. Métodos geoestadísticos

Moreno et al. (2007) exponen que los objetivos de las técnicas de interpolación geoestadística son generar superficies que incorporan las propiedades estadísticas de los datos muestrales y que proporcionan una media del error de las mismas, siendo este último un indicador de una buena o mala predicción. Todos los métodos geoestadísticos forman parte de la familia del kriging (nombre derivado de su inventor D. G. Krige).

4.2.2. Regresión - kriging

La forma simple de kriging es conocida como ordinary kriging (OK) que está basado en el siguiente modelo:

$$Z(s) = \mu + \varepsilon'(s)$$

Donde μ es una función estacionaria constante y $\varepsilon'(s)$ representa parte de variación estocástica de correlación espacial. El estimado de "Z" en una ubicación dada S_o es una combinación de valores muestreados dados:

$$\hat{Z}_{ok(S_o)} = \sum_{i=1}^n W_i(S_o) * Z(S_i) = \lambda_0^T * Z$$

Donde λ_0 es el vector de peso de OK kriging (W_i), y “Z” es el vector de muestras disponibles (medidas en ciertas ubicaciones). La solución del sistema de ecuaciones de los pesos W_i , usualmente referido como sistema ordinary kriging, puede ser expresado matricialmente de la forma:

$$\lambda_0 = C^{-1} \cdot c$$

Donde “C” representa la matriz de covarianzas entre todos los valores muestreados, y “Co” es el vector de covarianzas entre los puntos muestreados y el punto donde el valor es evaluado. Ok restringe la suma de los pesos a ser 1. En lugar de la evaluación de la función de covarianza $C(h)$ directamente, es común en geoestadística calcularlo indirectamente resolviendo la función de semivarianza $\gamma(h)$ o variograma.

$$\gamma(h) = \frac{1}{2} E[(Z(S_i) - Z(S_i + h))^2]$$

Donde h es la unidad de distancia o un retardo por el cual la semivarianza es determinada. La relación entre el variograma y la función covarianza es:

$$C(h) = C(0) - \gamma(h)$$

Dónde: $C(0)$ representa la varianza de la variable objetivo.

La principal hipótesis hecha en Ordinary kriging es que los datos son estacionarios. OK no es generalmente muy usado para datos no estacionarios. En el caso donde los datos presentan cambio de media y la tendencia es considerada como una función de coordenadas espaciales, Universal Kriging (UK) es usado como una extensión del ordinary kriging con cambio de media, donde la tendencia es modelada como una función de coordenadas. UK representa una combinación de una regresión lineal múltiple y ordinary kriging. Si la tendencia puede ser definida como una función lineal de variables auxiliares, entonces la técnica de predicción llamada KED o RK es usualmente utilizada. Usualmente, KED y RK son aplicados para unir diferentes fuentes de información. La variable objetivo con observaciones escasas y variables auxiliares que están disponibles de manera espacial.

Dado valores medidos de la variable objetivo se simboliza como $Z(S_i)$, $i = 1 \dots n$. donde, S_i representa la ubicación espacial y n el número de mediciones realizadas. El sistema de ecuaciones de la cual se obtiene el valor estimado de la variable objetivo es la siguiente:

$$\hat{Z}(S_0) = \hat{m}(S_0) + \hat{e}(S_0)$$

$$Z(S_0) = \sum_{k=0}^0 \hat{\beta}_k \cdot q_k(S_0) + \sum_{i=1}^n w_i(s_0) \cdot e(s_i); q_0(s_0) = 1$$

Donde $\hat{m}(S_o)$ es la parte determinística ajustada, $\hat{e}(S_o)$ es la parte residual interpolada, $\hat{\beta}k$ son coeficiente del modelo determinístico estimado, w_i son pesos del kriging para resolver la estructura espacial de los residuales $e(s_i)$. La esencial diferencia entre RK y KED, mientras los pesos KED son resueltos dentro de la matriz extendida de tendencia y residuales al mismo tiempo, en RK drift model, los coeficientes son calculados separadamente, y los residuales son interpolados por OK y sumados. Los coeficientes de regresión $\hat{\beta}k$ pueden ser obtenidos por diferentes métodos de ajustes, como mínimos cuadrados ordinarios o mínimos cuadrados generalizados (GLS), que es más recomendable:

$$\widehat{\beta}_{GLS} = (q^T \cdot C^{-1} \cdot q)^{-1} \cdot q^T \cdot C^{-1} \cdot z$$

Donde $\widehat{\beta}_{GLS}$ es el vector de coeficientes de regresión estimados, C matriz de covarianza de los residuales, q es matriz de predictores en la ubicación de la muestra y z es el vector de los valores medidos de la variable objetivo. El valor de la variable estimada $\hat{Z}(s_o)$ en la ubicación s_o , es obtenido por regression kriging, usualmente escrito en notación matricial:

$$\widehat{Z}_{RK}(S_o) = q_0^T \cdot \widehat{\beta}_{GLS} + \lambda_0^T \cdot (z - q \cdot \widehat{\beta}_{GLS})$$

Donde q_0 es el vector de p+1 predictores y λ_0 es el vector de n pesos de kriging usados para la interpolación de residuales.

4.2.3. Validación cruzada

La validación cruzada o cross-validation es una técnica utilizada para evaluar los resultados de un análisis estadístico y garantizar que son independientes de la partición entre datos de entrenamiento y prueba. Consiste en repetir y calcular la media aritmética obtenida de las medidas de evaluación sobre diferentes particiones. Se utiliza en entornos donde el objetivo principal es la predicción y se quiere estimar cómo de preciso es un modelo que se llevará a cabo a la práctica. Es una técnica muy utilizada en proyectos de inteligencia artificial para validar modelos generados.

4.2.4. Evapotranspiración potencial

Existen diversos métodos para estimar la evapotranspiración potencial. La FAO propone el método de Penman-Monteith (PM) (Allen et al, 1998) como el método estándar. Sin embargo, el cálculo de PM necesita una gran cantidad de datos, como radiación solar, velocidad del viento, humedad relativa, los cuales no se encuentran disponibles en la zona de estudio.

Muchos autores proponen el método empírico basado en la ecuación de Hargreaves (HG) (Hargreaves y Samani, 1985) como la mejor alternativa donde los datos son escasos (Martínez-Cob, 2002; Vicente-Serrano et al., 2014; Xu y Singh, 2001). Estos métodos solo requieren información de Temperatura máxima y mínima y radiación extraterrestre (Ra). Debido a que Ra puede ser calculada teóricamente (Droogers y Allen, 2002), las únicas variables requeridas serían las temperaturas. Droogers y Allen (2002) modificaron la ecuación original de HG incluyendo la precipitación P, asumiendo que la precipitación mensual puede representar

niveles de humedad y radiación solar. La evapotranspiración en mm/días es calculada de la siguiente manera:

$$ET_o = 0.0013 * Ra(T + 17.0)(R - 0.0123 * P)^{0.76}$$

Donde P es la precipitación mensual en mm, R es la diferencia entre la temperatura máxima y mínima (media mensual, °C) y Ra es la radiación solar extraterrestre (mm/día).

4.2.5. Modelo de balance hídrico para estimar escurrimiento

La disponibilidad hídrica puede ser calculada mediante el modelo de Budyko calcula la evapotranspiración potencial (ETp) de cada pixel en base a la evapotranspiración de referencia (ETo) y un coeficiente de vegetación (Kc):

$$ET_p = Kc * ET_o$$

La evapotranspiración potencial ETP se transforma a evapotranspiración real ETR mediante la expresión de Budyko, la cual se presenta en la siguiente ecuación:

$$ETR = \left[ETP * P * \tan \left[\frac{P}{ETP} \right] * \left[1 - \cosh \left[\frac{ETP}{P} \right] + \sinh \left[\frac{ETP}{P} \right] \right] \right]^{0.5}$$

Finalmente, se define la cantidad de agua disponible para extracción como la diferencia entre la precipitación y la evapotranspiración actual. Es decir la cantidad de precipitación que constituye la escorrentía superficial más la recarga de los acuíferos subterráneos, es igual a la precipitación efectiva:

$$P_{eff} = P - ET_a$$

5. RESULTADOS Y DISCUSIÓN

5.1. PRECIPITACIÓN

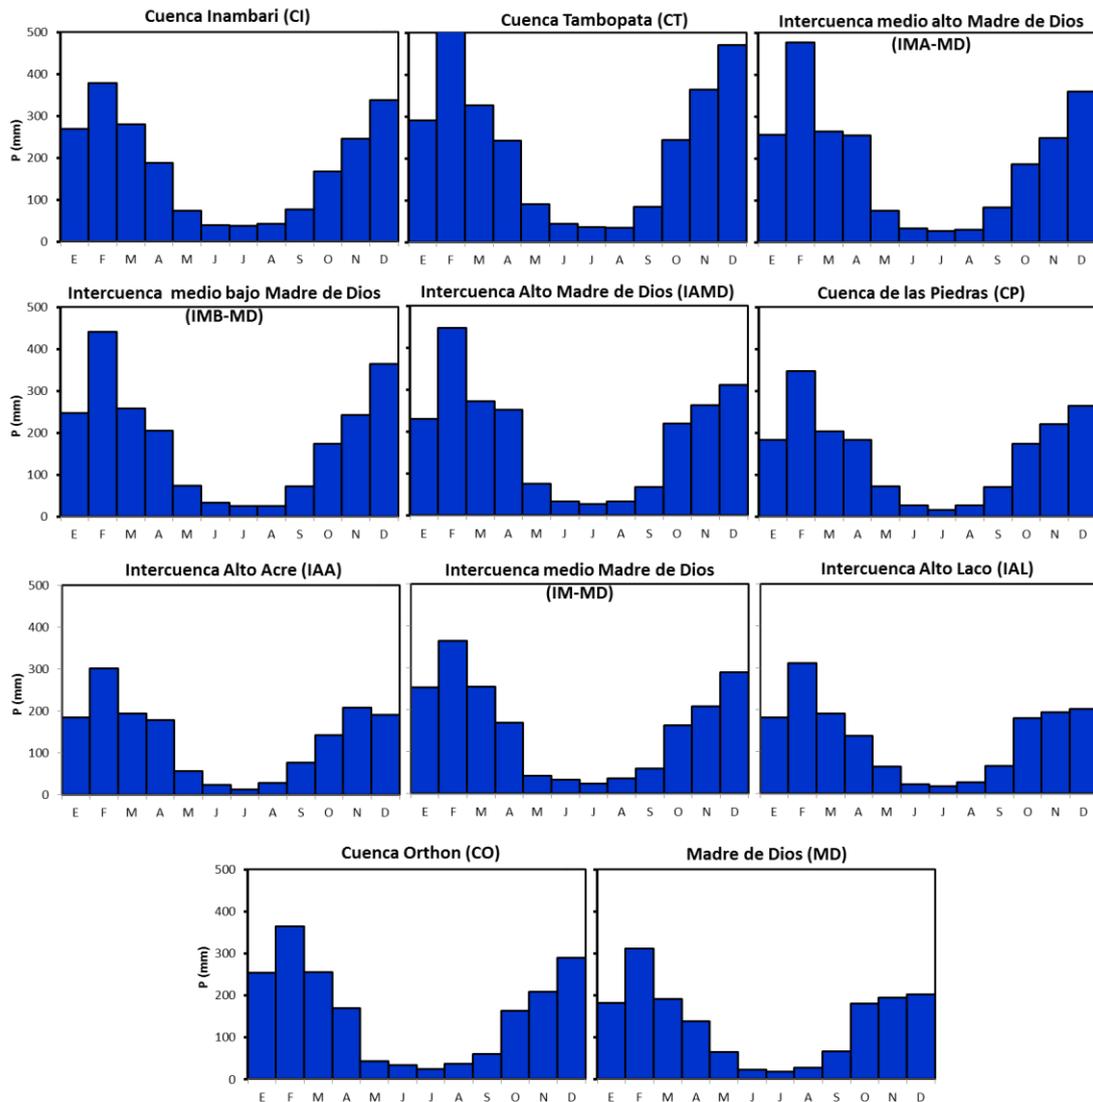


Figura 5 - 1. Precipitación media areal para el año promedio (1981-2015) de las cuencas de la región de Madre de Dios

La Figura 5-1 muestra la precipitación media areal en barras para el año promedio (1981-2015) de las cuencas de la región de Madre de Dios. Así como el valor de su régimen mensual, mostrado en la Tabla 3. En la cual se puede observar que existe un comportamiento estacional de las lluvias, presentándose los mayores acumulados entre Enero a Abril y Octubre a Diciembre, donde el mayor acumulado de precipitación se presenta en Febrero. Los meses de menor precipitación se presentan entre Junio, Julio y Agosto.

Las cuencas de la región Madre de Dios, presentan una precipitación promedio multianual por encima de 1600 mm/añual, siendo las cuencas CO, CP, IAL, IAA las menos húmedas, teniendo una

precipitación anual promedio entre 1599.5 a 1793.0 mm, el resto de las cuencas presentan una precipitación anual promedio de entre 1793.0 a 2740.4 mm, siendo estas las más húmedas en la región. Especialmente, las mayores precipitaciones estimados a lo largo de todo el año se presenta al sur de la región Madre de Dios, específicamente sobre la parte baja de la Intercuenca Alto Madre de Dios, Cuenca Inambari, cuenca Tambopata e Intercuenca Medio Alto Madre de Dios (ver mapa MDD-01), (Anexo 1).

Tabla 3: Precipitación del ciclo anual promedio (1981-2015) en las cuencas de la región Madre de Dios

UH / mes	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC	Acumulado Anual
CI	269.2	378.9	279.8	187.3	74.1	39.9	38.9	43.7	77.9	167.6	245.8	337.3	2140.4
CT	290.3	506.7	327.7	243.4	90.9	44.2	37.4	34.5	84.8	244.2	365.1	471.2	2740.4
IMAMD	256.5	476.1	264.2	255.4	75.6	34.1	27.1	31.2	82.8	186.7	248.4	360.3	2298.4
IMBMD	247.3	441.1	259.06	204.7	73.4	32.9	25.4	26.1	71.8	174.7	242.4	364.8	2163.7
IAMD	230.4	446.9	272.8	252.1	76.2	34.2	27.4	33.4	67.8	218.8	262.7	311.9	2234.6
CP	183.7	347.1	204.3	183.1	73.2	27.4	16.5	27.2	70.7	173.6	221.4	264.8	1793.0
IAA	185.0	302.4	194.72	178.4	56.6	23.9	13.9	28.1	76.5	143.3	208.7	191.5	1603.0
IMMD	253.7	364.9	255.9	169.3	43.5	32.8	24.2	36.6	59.7	163.1	208.5	290.1	1902.3
IAL	182.4	311.9	191.2	138.2	64.1	22.5	17.9	26.7	66.9	180.4	195.1	202.2	1599.5
CO	184.8	324.7	206.3	190.4	60.7	25.3	13.5	27.1	69.2	152.4	198.1	240.5	1693.0
MD	215.5	411.1	244.2	222.1	75.1	32.1	22.8	30.2	72.2	196.2	247.3	300.6	2069.4

UH: Unidad Hidrográfica

5.2. EVAPOTRANSPIRACIÓN POTENCIAL

La evapotranspiración potencial, en las cuencas de la región Madre de Dios, presenta una demanda media mensual que fluctúa de 40 a 70 mm/mes, siendo estas demandas mayores de Septiembre a Marzo y de menor evapotranspiración potencial de Junio y Julio (Figura 5-2). La evapotranspiración potencial media anual en las cuencas de la región Madre de Dios se estima que es alrededor de los 51 a 66 mm/mes (Tabla 4).

Especialmente, la menor evapotranspiración estimada a lo largo de todo el año, se centra en la parte noroeste de la región Madre de Dios que comprende a la Intercuenca Alto Madre de Dios (ver mapa MMD-02), (Anexo I).

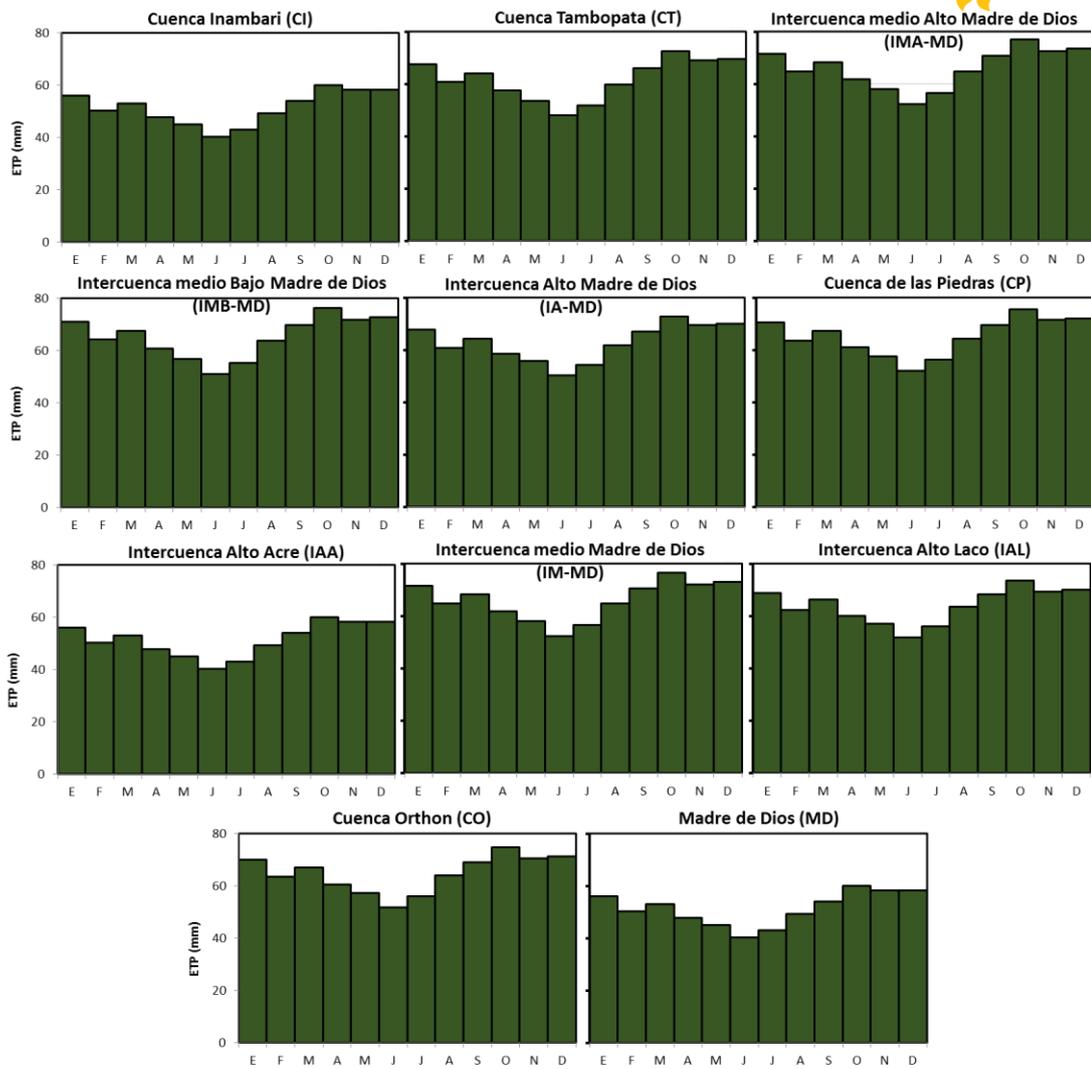


Figura 5 - 2. Evapotranspiración potencial media areal para el año promedio (1981-2015) de las cuencas de la región de Madre de Dios.

Tabla 4: Evapotranspiración potencial para el año promedio (1981-2015) en las cuencas de la región Madre de Dios

UH / mes	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC	Promedio
CI	55,94	50,31	53,10	47,82	44,99	40,24	43,00	49,41	54,15	59,98	58,24	58,20	51,28
CT	67,57	60,87	64,03	57,48	53,51	48,03	51,86	59,92	65,98	72,59	69,08	69,63	61,71
IMAMD	71,63	64,86	68,32	61,80	57,98	52,25	56,61	64,91	70,80	77,15	72,66	73,49	66,04
IMBMD	70,96	64,21	67,57	60,83	56,84	51,14	55,37	63,74	69,75	76,21	71,79	72,68	65,09
IAMD	67,71	60,92	64,26	58,63	55,72	50,30	54,28	61,74	66,93	72,75	69,59	69,93	62,73
CP	70,46	63,66	67,19	60,96	57,58	52,04	56,37	64,29	69,67	75,49	71,43	72,15	65,11
IAA	69,14	62,76	66,57	60,22	56,99	51,61	55,85	63,59	68,42	73,84	69,39	70,21	64,05
IMMD	71,65	64,91	68,39	61,72	57,94	52,23	56,56	64,85	70,53	76,57	71,94	73,03	65,86
IAL	68,83	62,37	66,19	60,11	57,03	51,73	56,00	63,59	68,33	73,59	69,38	70,07	63,94
CO	69,99	63,43	67,08	60,65	57,21	51,72	56,02	63,95	69,15	74,89	70,54	71,34	64,66
MD	69,73	62,99	66,48	60,34	57,03	51,51	55,73	63,57	68,92	74,78	70,86	71,51	64,45

5.3. ESCURRIMIENTO SUPERFICIAL

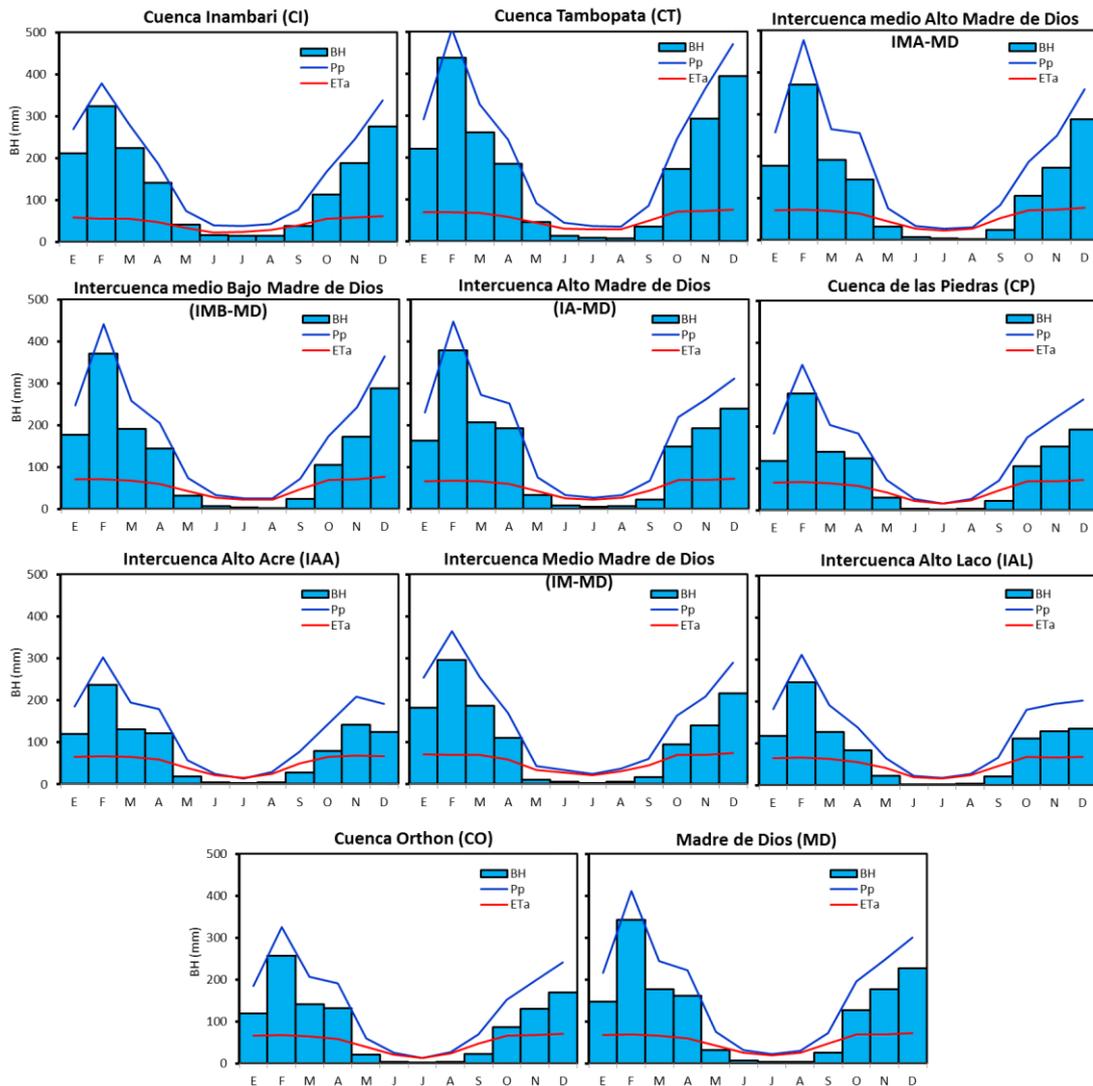


Figura 5 - 3. E scorrimiento superficial medio areal para el año promedio (1981-2015) de las cuencas de la región de Madre de Dios. BH=escurrimento superficial (mm), P=Precipitación (mm), Eta=Evapotranspiración actual (mm)

Observando las barras de escurrimento superficial en las cuencas de la región Madre de Dios (Figura 5-3), se puede apreciar que existe un comportamiento estacional, presentándose la mayor disponibilidad hídrica de Enero a Abril y de Octubre a Diciembre. Y, de menor disponibilidad hídrica, se presentan en los meses de Junio, Julio, Agosto y Septiembre. La Tabla 5, presentan la disponibilidad hídrica medio anual en las cuencas de la región Madre de Dios, con valores por encima de 80 mm/mes. Además, se observa que las cuencas satisfacen la demanda hídrica a lo largo de todo el año.

Al igual que la precipitación, espacialmente los mapas de escurrimento medio mensual se presentan al sur de la región Madre de Dios (ver mapa MDD-03), (ANEXO 1).

Tabla 5: E scorrimiento superficial para el año promedio (1981-2015) en las cuencas de la región Madre de Dios.

UH / mes	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC	Promedio
CI	211,04	323,46	224,25	140,47	40,57	16,51	15,01	14,51	37,65	112,95	187,80	275,72	133,33
CT	220,75	437,80	259,76	184,66	46,71	13,57	8,83	6,21	35,16	173,15	292,34	394,79	172,81
IMAMD	184,75	403,78	194,85	192,21	31,68	6,56	3,64	4,22	30,94	115,32	176,35	283,02	135,61
IMBMD	176,68	370,18	190,69	144,53	31,24	6,41	3,38	2,93	23,85	105,34	171,91	288,23	126,28
IAMD	163,77	379,07	207,05	192,00	33,55	8,42	5,27	6,34	23,28	149,09	192,85	240,05	133,39
CP	117,61	279,03	139,20	124,37	29,64	4,18	0,82	3,16	23,16	104,69	151,81	192,48	97,51
IAA	119,60	236,4	130,55	120,24	17,90	3,10	0,22	3,46	27,30	78,69	141,48	124,82	83,66
IMMD	182,08	295,19	186,88	110,62	9,87	5,98	2,85	5,89	15,72	94,41	139,30	215,64	105,37
IAL	117,43	246,05	127,52	83,22	23,05	2,73	1,10	3,09	20,97	11,14	128,76	134,83	83,41
CO	118,73	257,48	141,06	131,38	20,73	3,48	0,28	3,18	22,21	86,05	130,88	169,95	90,45
MD	148,09	342,24	177,88	162,02	32,01	7,04	3,44	4,59	24,98	126,49	177,24	227,82	119,48

6. CONCLUSIONES

- En términos generales las cuencas de la Región Madre de Dios presentan un comportamiento estacional en las variables de precipitación, evapotranspiración potencial y escurrimento superficial, descritos a partir de las gráficas de barras y tablas.
- Los meses más húmedos se da entre Enero a Abril y, que espacialmente se registran a lo largo del todo el año, al sur de la región Madre de Dios.
- Los cambios en la evapotranspiración potencial estimada a lo largo del año no es significativa la cual fluctúa de 40 a 70 mm/ mes.
- Se estima que el mayor escurrimento medio areal anual se presenta en la cuenca de Tambopata (172,81 mm/ mes); siendo febrero el mayor mes aportante, con una disponibilidad hídrica de 437,8 mm/mes.

7. BIBLIOGRAFÍA

- Allen, R.G., Pereira, L.S., Raes, D., Smith, M. (1998) *Crop evapotranspiration —guidelines for computing crop water requirements*. FAO Irrigation and drainage paper 56. Food and Agriculture Organization, Rome.
- Carpenter, T.M., Georgakakos, K.P., (2006). Intercomparison of lumped versus distributed hydrologic model ensemble simulations on operational forecast scales. *Journal of Hydrology*, 329(1-2): 174-185.
- Droogers, P. and Allen, R.G. (2002) Estimating Reference Evapotranspiration under Inaccurate Data Conditions. *Irrigation and Drainage Systems*, 16, 33-45. <http://dx.doi.org/10.1023/A:1015508322413>
- Espinoza JC, Ronchail J, Guyot JL, et al (2009) Spatio-temporal rainfall variability in the Amazon basin countries (Brazil, Peru, Bolivia, Colombia, and Ecuador). *Int J Climatol* 29:1574–1594. doi: 10.1002/joc.1791
- Ferraro, R.R. y G.F. Marks, 1995: The development of SSM/I rain-rate retrieval algorithms using ground-based radar measurements. *Journal of Atmospheric Oceanic Technology*, 12, 755–770.
- Giraldo, R. 2005. Introducción a la Geoestadística. Universidad Nacional de Colombia. Bogotá, CO. 94 p.
- Grimes, D., Diop, M., 2003. Satellite-based rainfall estimation for river flow forecasting in Africa: Part 1. Rainfall estimates and hydrological forecasts. *Hydrological Sciences Journal* 48 (4), 567–584.
- Hargreaves GH, Samani Z a. (1985) Reference crop evapotranspiration from temperature. *Appl Eng Agric* 1:96–99. doi: 10.13031/2013.26773
- Hong, Y; Gochis, D; Cheng, J. 2007. Evaluation of PESIANN-CCS rainfall measurement using the NAME event rain gauge network. *Journal Hydrometeorology* 8: 469-482.
- Hong, Y; Hsu K; Gao, X. 2004. Precipitation estimation from remotely sensed imagery using artificial neural network-cloud classification system. *Journal of Applied Meteorology* 43: 1834-1853.
- Hsu, K., H.V. Gupta, X. Gao, S. Sorooshian, 1999: A neural network for estimating physical variables from multi-channel remotely sensed imagery: application to rainfall estimation. *Water Resources Research*, 35, 1605–1618.
- Hughes, D.A., 2006. An evaluation of the potential use of satellite rainfall data for input to water resource estimation models in southern Africa. *IAHS Publication* 308, 75–80.
- Hsu, K., Gupta, H.V., Gao, X., Sorooshian, S., 1999. Estimation of physical variables from multi-channel remotely sensed imagery using a neural network: application to rainfall estimation. *Water Resources Research* 35 (5), 1605–1618
- Huffman, G.; Adler, R.; Arkin, P.; Chang, A.; Ferraro, R.; Gruber, A.; Janowiak, J.; McNab, A.; Rudolf, B.; Schneider, U. 1997: The global precipitation climatology project (GPCP) combined precipitation dataset *Bull. Am. Meteorol. Soc.*, 78 (1) (1997), pp. 5-20
- Huffman, G.; Adler, R.; Bolvin, D.; GU. G.; Nelkin, E.; Bowman, K.; Hong, Y.; Stocker, E.; Wolff, D. 2007. The TRMM Multisatellite Precipitation Analysis (TMPA): quasi-global, multiyear, combined sensor precipitation estimates at fine scales. *Journal of Hydrometeorology*, Boston, v. 8, n. 1, Feb., p. 38–55.
- Kummerow, C., W. S. Olson, and L. Giglio, 1996: A simplified scheme for obtaining precipitation and vertical hydrometer profiles from passive microwave sensors. *IEEE Trans. Geosci. Remote Sens.*, 34, 1213–1232.

- Kummerow, C., W. Barnes, T. Kozu, J. Shiue, y J. Simpson, 1998: The tropical rainfall measurement mission (TRMM) sensor package. *Journal of Atmospheric Oceanic Technology*, 15, 809–816.
- Kuo-Lin, H; Behrangi, A; Bisher, I. 2010. Extreme precipitation estimation using satellite-based PERSIANN-CCS algorithm. *Satellite Rainfall Applications for Surface Hydrology*: 49-67.
- Nair, S., Srinivasan, G., Nemani, R., 2009. Evaluation of multi-satellite TRMM derived rainfall estimates over a Western State of India. *Journal of the Meteorological Society of Japan* 87 (6), 927–939.
- Salzmann, N. et al., (2009). Integrated assessment and adaptation to climate change impacts in the Peruvian Andes. *Adv. Geosci.*, 22: 35-39.
- Sorooshian, S., Hsu, K., Gao, X., Gupta, H.V., Imam, B., Braithwaite, D., 2000. Evaluation of PERSIANN system satellite-based estimates of tropical rainfall. *Bulletin of the American Meteorological Society* 81 (9), 2035–2046.
- Stisen, S., Sandholt, I., 2010. Evaluation of remote-sensing-based rainfall products through predictive capability in hydrological runoff modeling. *Hydrological Processes* 24 (7), 879–891.
- Vila, D.A.; Gonçalves, L.G.G.; Toll, D.L.; Rozante, J.R. 2009. Statistical evaluation of combined daily gauge observations and rainfall satellite over continental South America. *Journal of Hydrometeorology*, Boston, v. 10, n. 2, Apr., p. 533-543.
- Vila, D., R. Ferraro, and R. Joyce, 2007: Evaluation and improvement of AMSU precipitation retrievals. *J. Geophys. Res.*, 112, D20119, doi:10.1029/2007JD008617.
- Zhao, L., Weng, F. (2002). Retrieval of Ice Cloud Parameters Using the Advanced Microwave Sounding Unit. *J. Appl. Meteor.*, 41, 384–395.

8. ANEXO

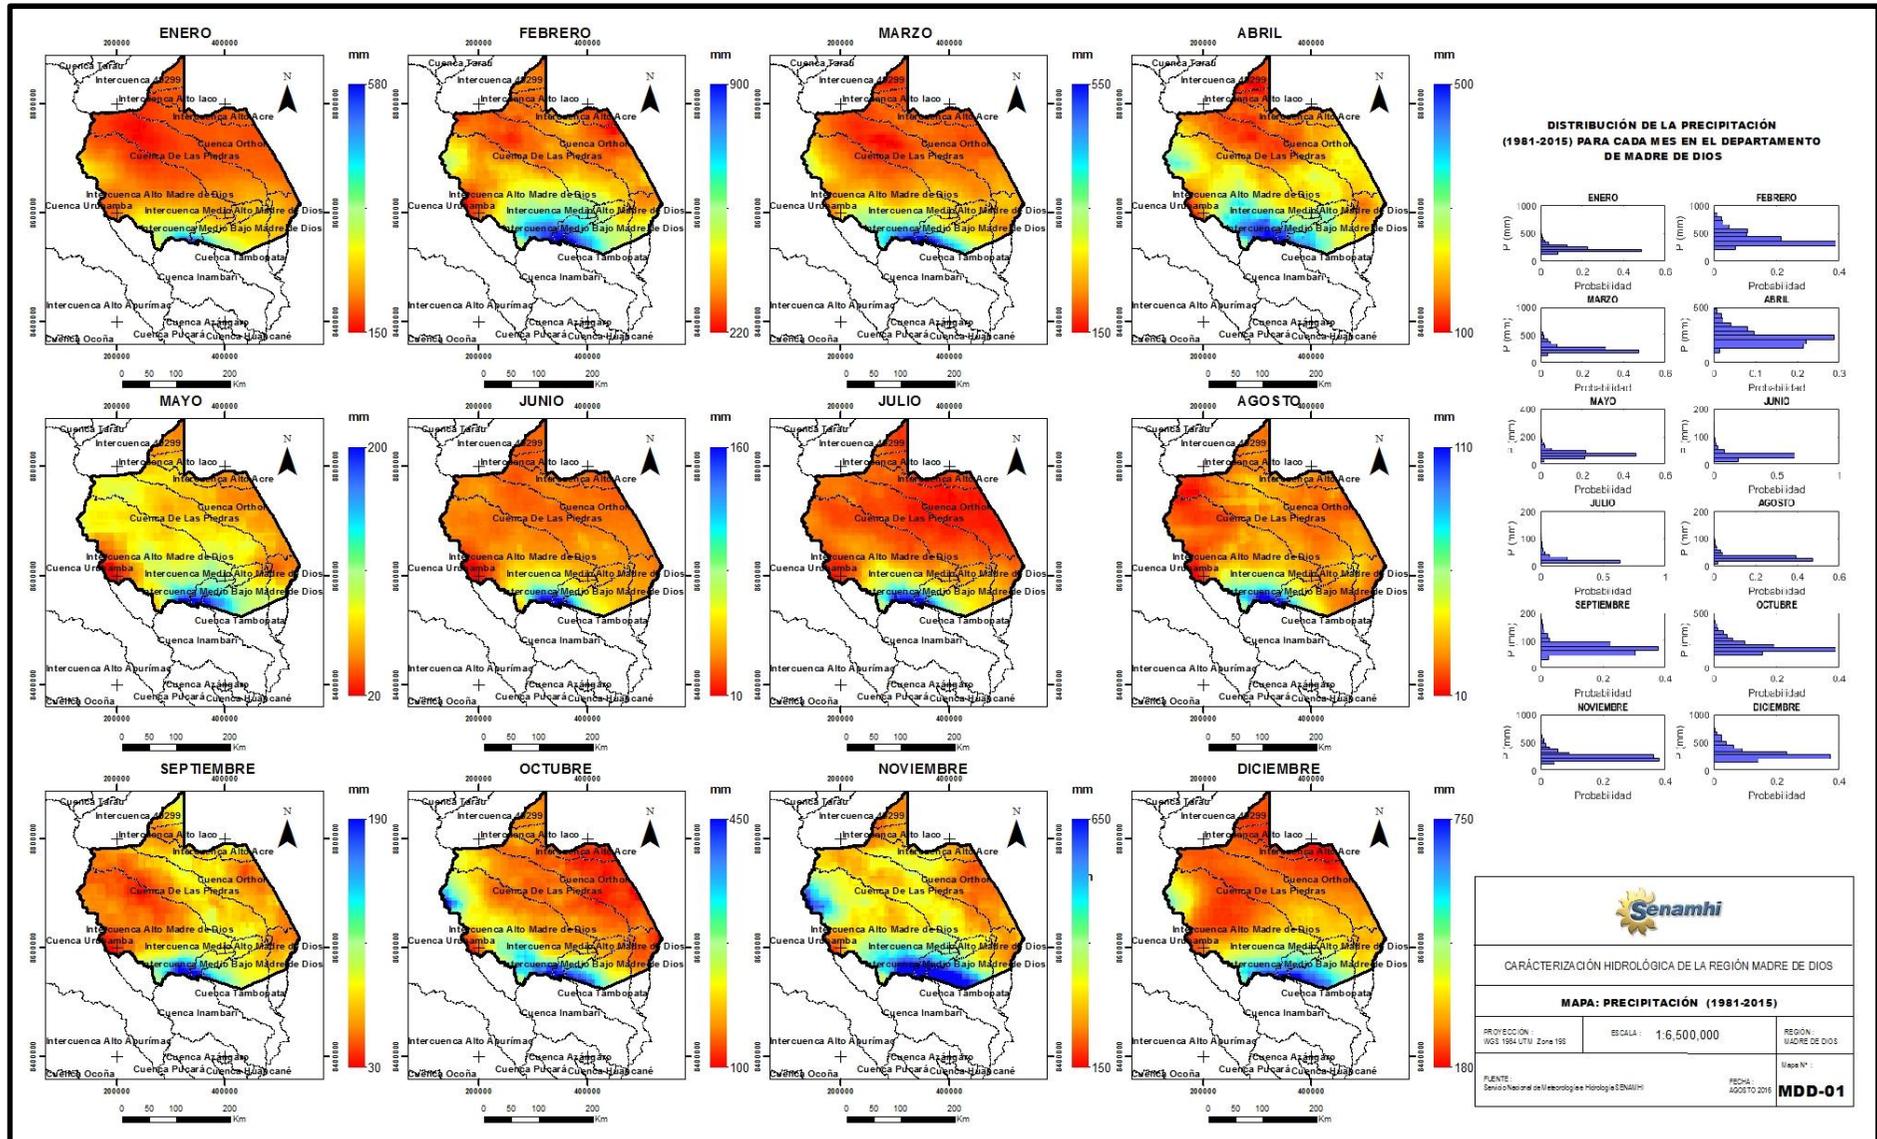


Figura 8 - 1. Mapa de precipitación media areal para el año promedio (1981-2015) de las cuencas de la región de Madre de Dios

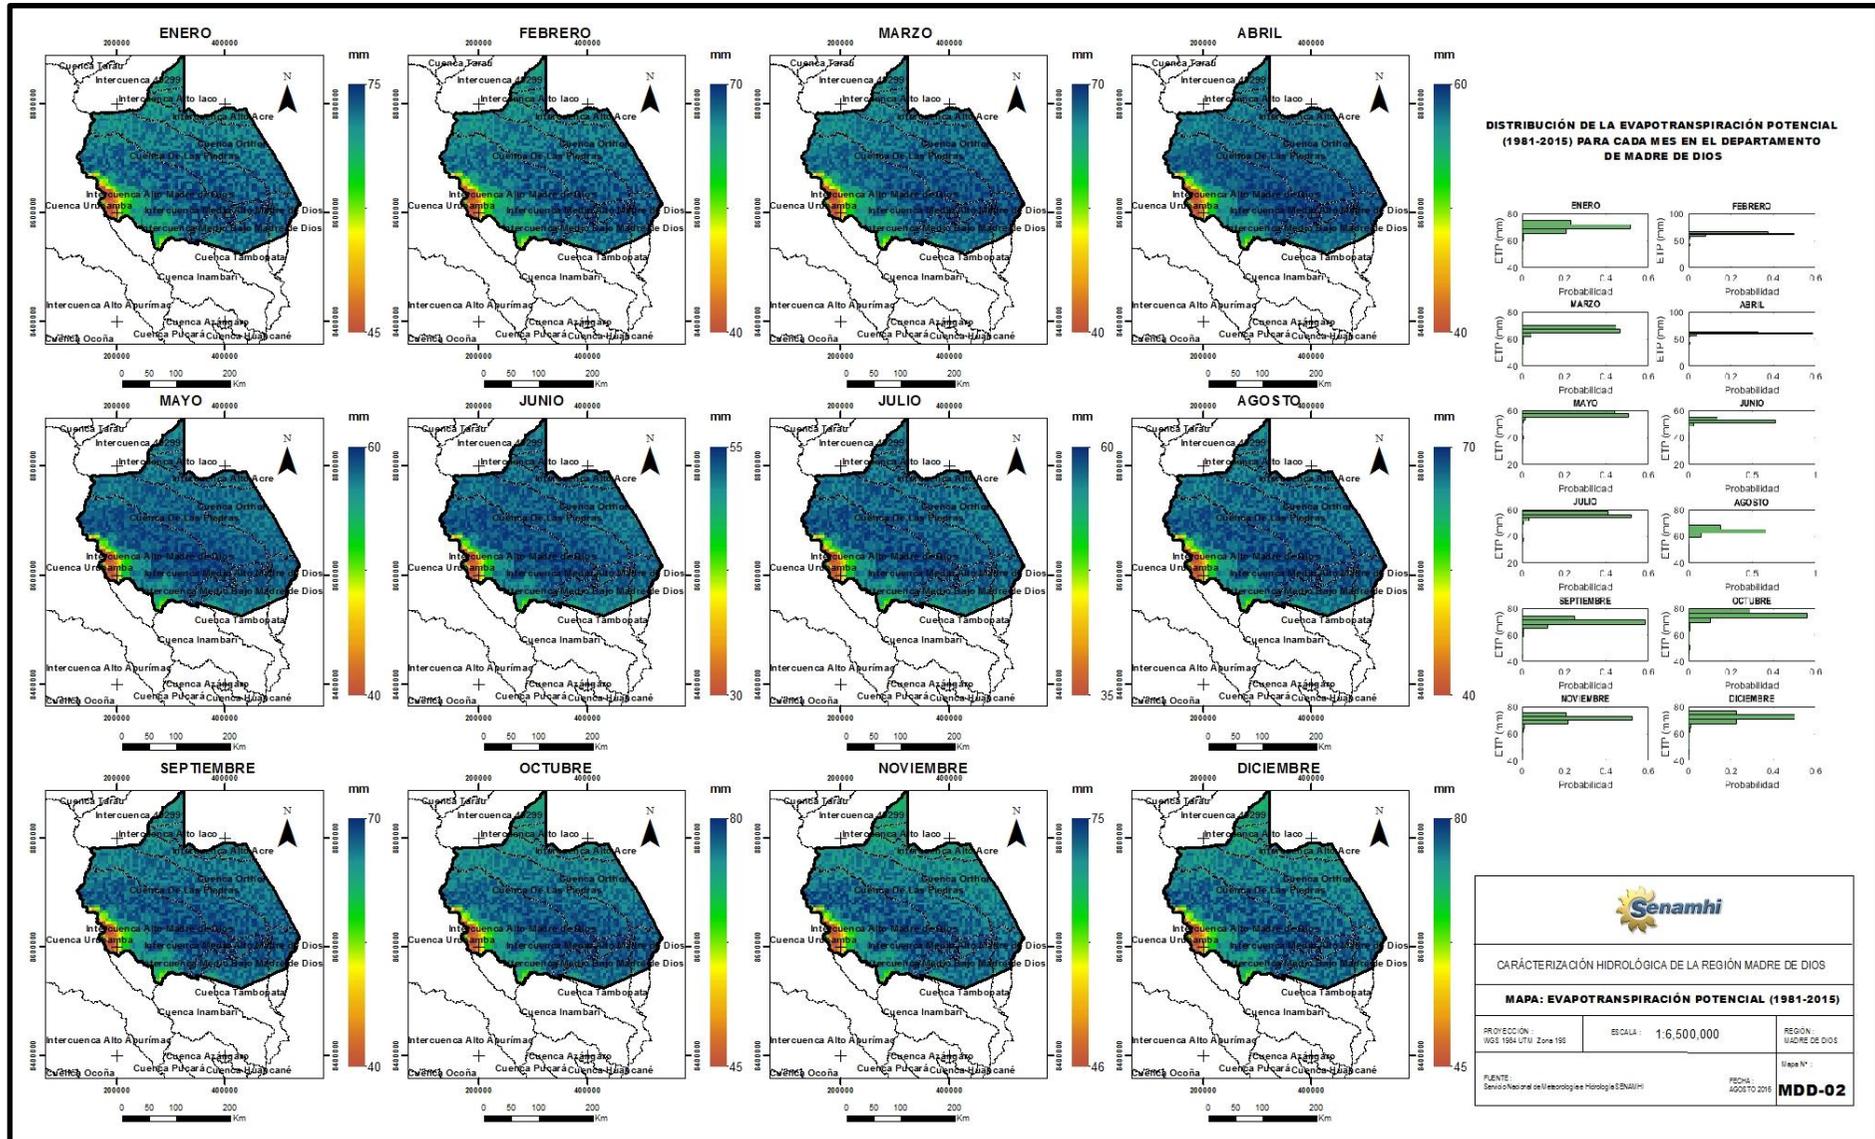


Figura 8 - 2. Mapa de evapotranspiración potencial media areal para el año promedio (1981-2015) de las cuencas de la región de Madre de Dios

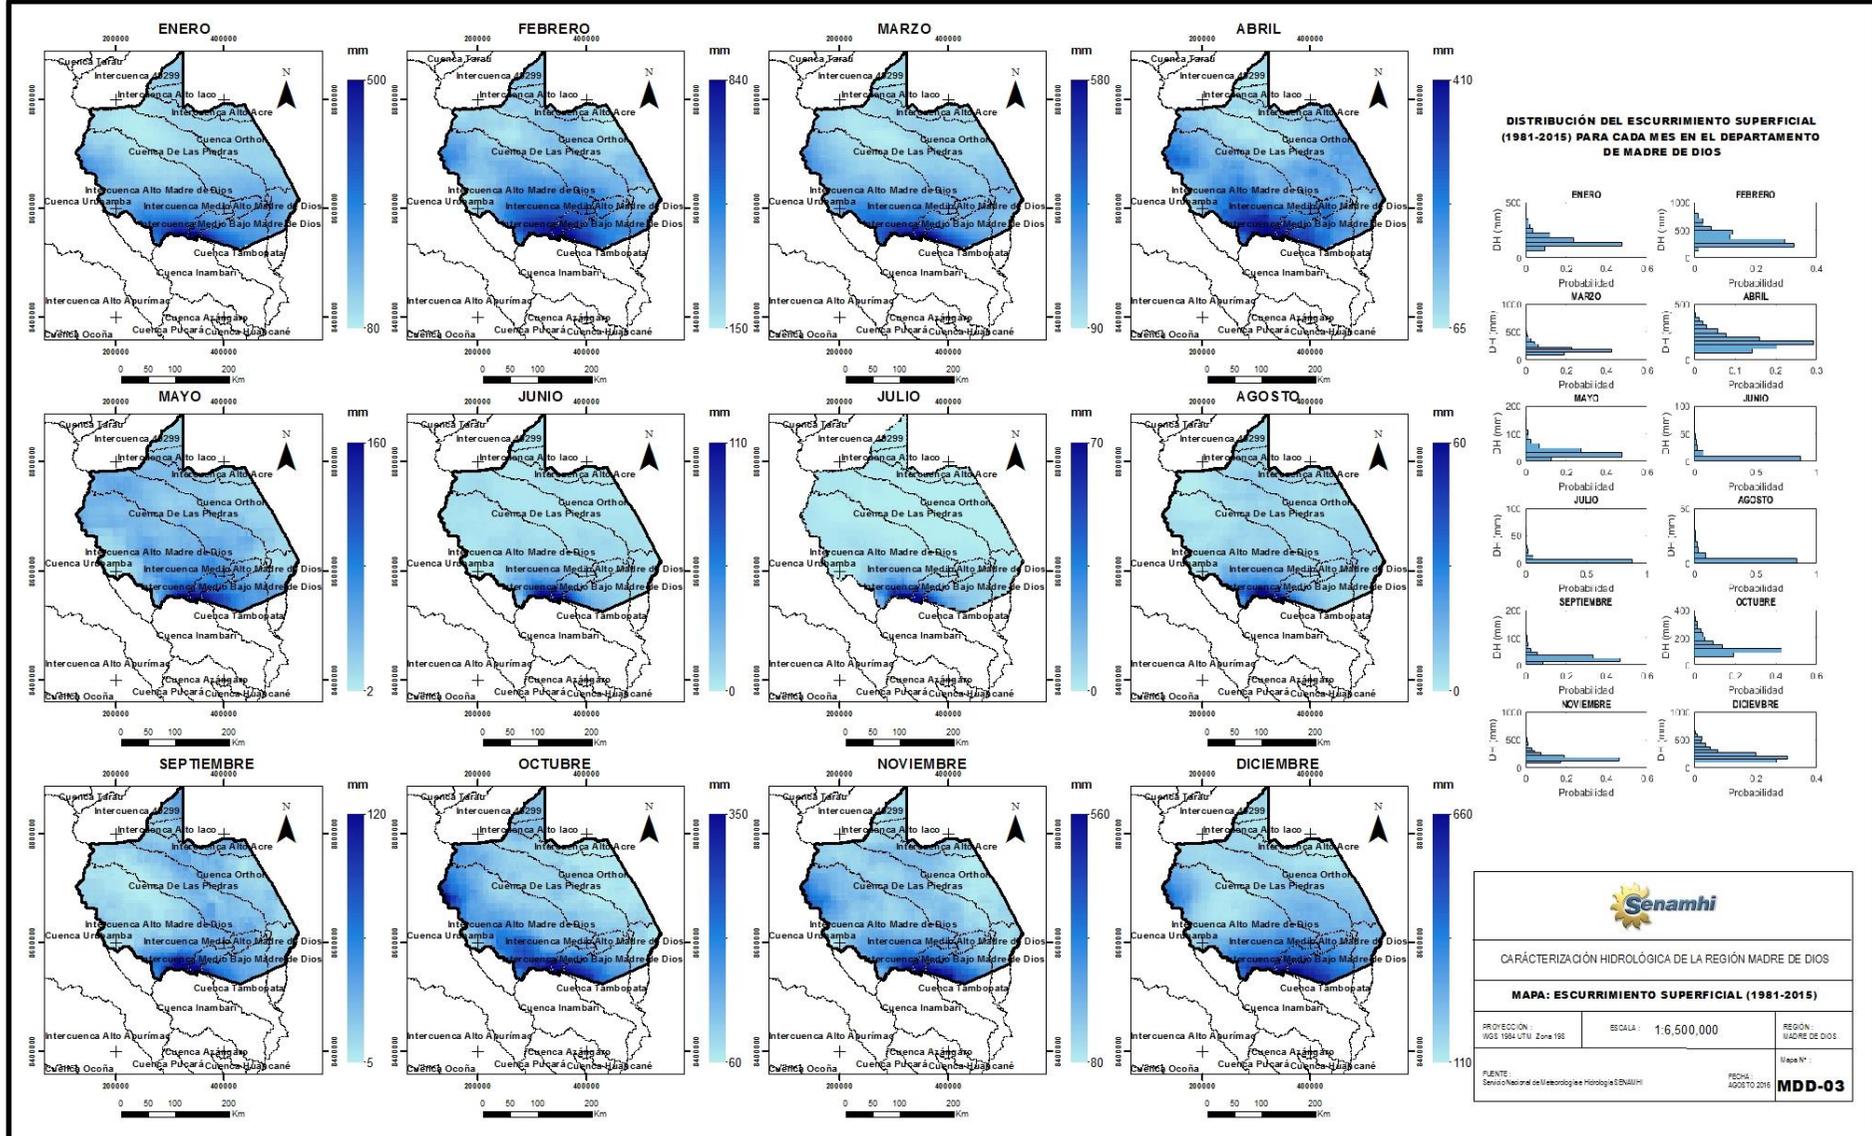


Figura 8 - 3. Mapa de escurrimiento superficial para el año promedio (1981-2015) de las cuencas de la región de Madre de Dios

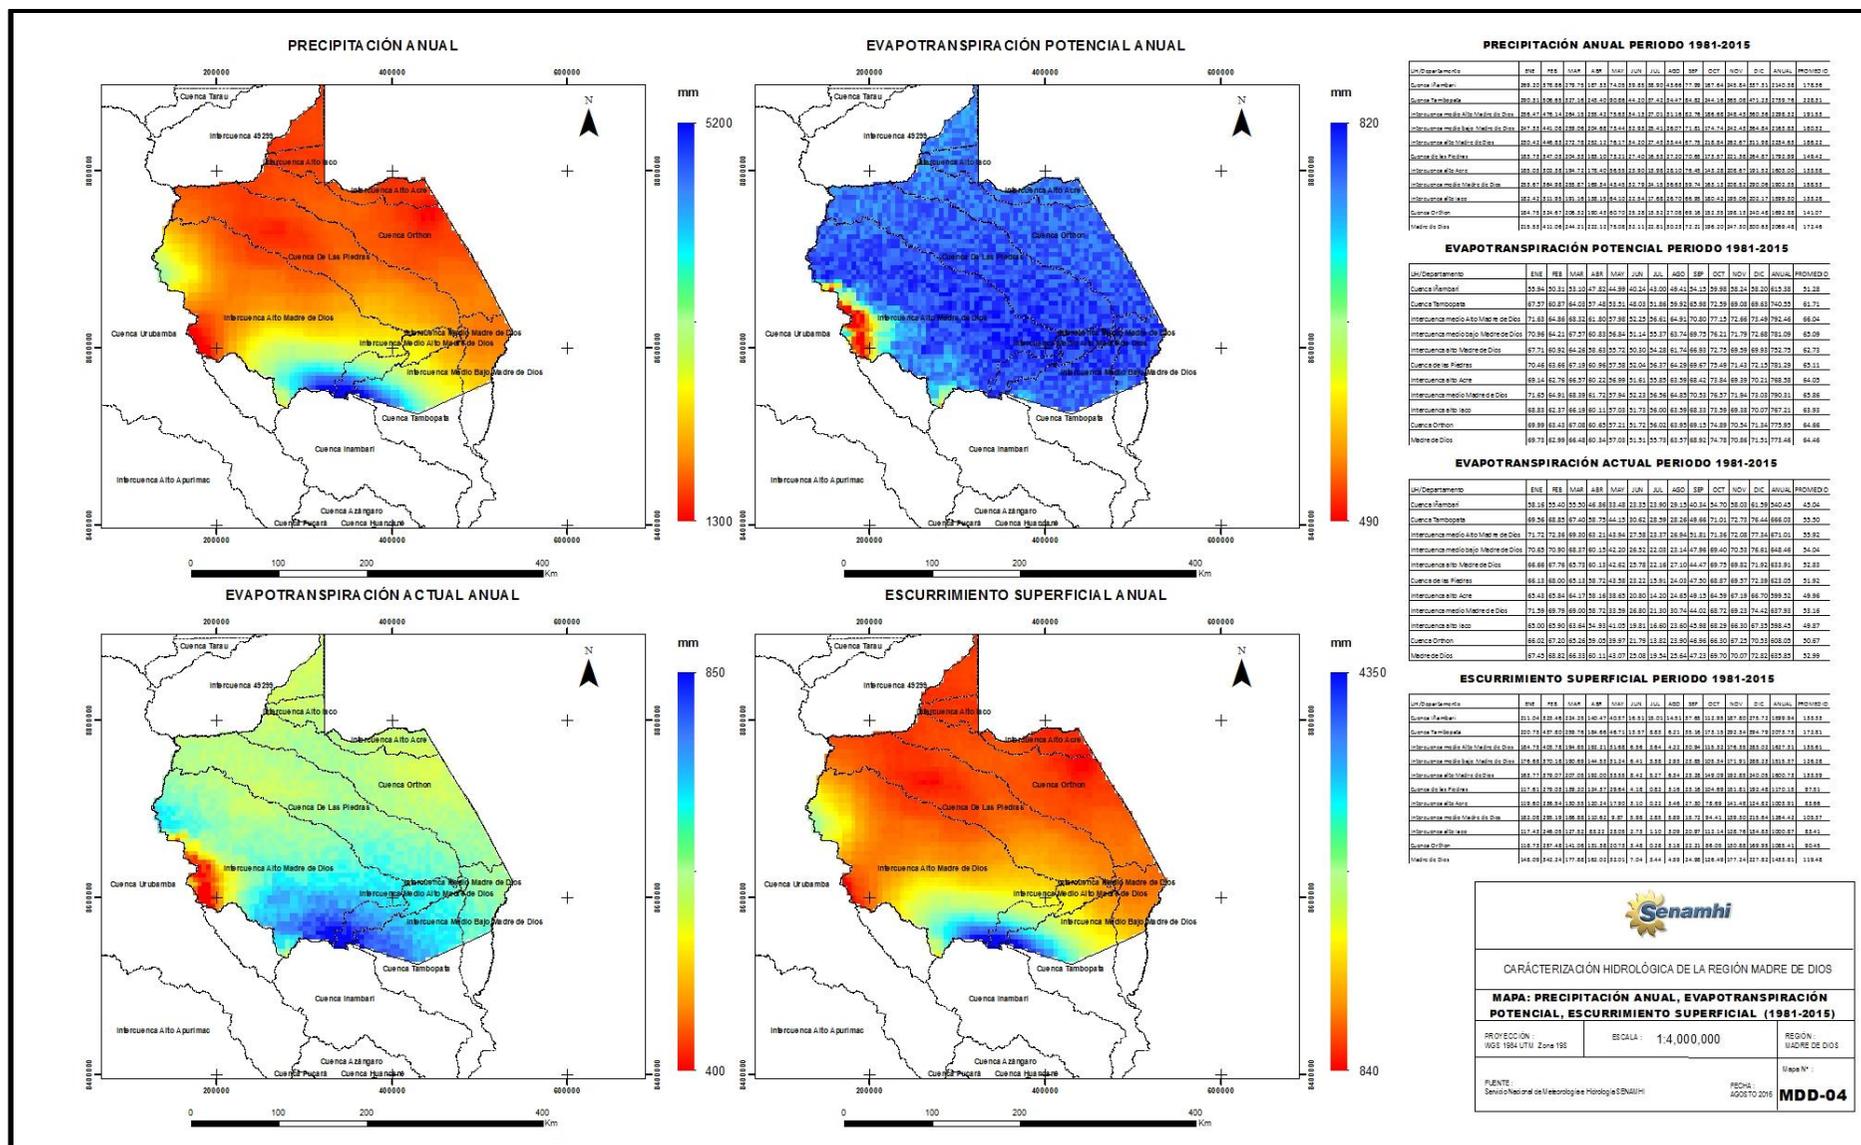


Figura 8 - 4. Mapa de precipitación, evapotranspiración potencial, actual y escurrimiento superficial medio anual para el año promedio (1981-2015)