



UNIVERSIDAD NACIONAL DE COLOMBIA
SEDE BOGOTÁ

ESTIMACIÓN DE CAUDALES A PARTIR DE ENSAMBLES HIDROLÓGICOS MULTIMODELO A DIFERENTES ESCALAS TEMPORALES EN LA CUENCA DEL RÍO PRADO

Jeffer Cañón Hernández

Trabajo de grado para optar por el título de
Magíster en Ingeniería – Recursos Hidráulicos

Director:

Néstor Alonso Mancipe Muñoz

Codirector:

David Andrés Zamora Ávila

Universidad Nacional de Colombia
Facultad de Ingeniería
Departamento de Ingeniería Agrícola y Civil
Maestría en Ingeniería Recursos Hidráulicos
Bogotá D.C., 2019

AGRADECIMIENTOS

A mi madre por todo el sustento e incondicional apoyo.

A mi esposa por todos los años de amor e incentivo por alcanzar mis metas.

A la inspiración y motivación que recientemente llegó a mi vida, mi hija.

Al ingeniero David Zamora por su dedicación, guía y acertados comentarios.

Al ingeniero Néstor Mancipe por la claridad de sus orientaciones.

RESUMEN

Los modelos hidrológicos son imperfectos y sus incertidumbres difieren para la predicción de un mismo evento hidrológico. Esto se debe a que la estructura de los modelos es una representación simplificada del comportamiento agregado de procesos naturales muy complejos y muy variables. En los últimos años, la estimación de caudales por medio de ensambles hidrológicos ha ganado espacio en los centros de predicción hidrológica del mundo, ya que no solo mejora las estimaciones, sino que ofrece un rango de los posibles resultados, es decir que los ensambles permiten abordar la incertidumbre asociada a diferentes fuentes y obtener resultados más útiles y confiables para la toma de decisiones.

En la búsqueda de mejorar la estimación de caudales, se construyeron y evaluaron ensambles hidrológicos multimodelo para la cuenca del río Prado y dos de sus subcuencas (Cunday y San Pablo), tanto a escala diaria como mensual, para el periodo 1981-2011. La estimación se basó en establecer mejores ensambles promedio, desde el resultado de dos métricas determinísticas y una probabilística, evaluadas en las posibles combinaciones de las series de caudales resultantes de 17 modelos hidrológicos con escalas espaciales, estructuras, conceptos y enfoques diferentes (*i. e.*, model-driven y data-driven). Posteriormente, los miembros (modelos) de los mejores ensambles promedio según cada métrica fueron valorados mediante el método del Modelo Bayesiano Promedio (en inglés BMA) para conocer su participación o peso dentro de estos mejores ensambles. Con los pesos conocidos se generaron tres nuevos ensambles que fueron evaluados en su desempeño frente a los anteriores ensambles promedio y los mejores modelos para las dos escalas temporales evaluadas, tanto a escala de cuenca como de sus subcuencas. Por otra parte, el BMA permitió establecer que los modelos de escala local (SWAT y algoritmo *deep learning*) tienen mayor importancia en la mejora de la estimación de caudales, ya que sus pesos en el ensamble fueron mayores a los demás modelos evaluados. Finalmente, modificando los pesos, anteriormente obtenidos, se estimó la franja de incertidumbre de cada ensamble, con el fin de evaluarla mediante tres criterios.

El desempeño de los tres ensambles que consideran los pesos según las métricas determinísticas y probabilística aumentó permitiendo mejorar la estimación de los caudales y la franja de incertidumbre evaluada en los tres ensambles mostró que el ensamble según la métrica probabilística se redujo.

Palabras claves: Ensamble hidrológico, estimación de caudales, BMA, cuenca del río Prado, Deep Learning, SWAT

ABSTRACT

Hydrological models are imperfect and their uncertainties fluctuate for the prediction of the same hydrological event. This is because the model' structure is a simplified representation of the aggregate behavior of highly complex and highly variable natural processes. Recently, the estimation of flows through the hydrological ensemble has gained space in the hydrological prediction agencies around the world, because not only improves the estimates but also offers a range of probabilistic results. The ensembles allow addressing the uncertainty associated to different sources to get more useful and reliable estimation for stakeholders.

In the search to improve the flow estimation, multi-model hydrological ensembles were constructed and evaluated for the Prado river basin and two of its sub-basins (Cunday and San Pablo), both on a daily and monthly scale for the period 1981-2011. The estimation was based on establishing the best average ensembles according to two deterministic and probabilistic metrics, evaluated in the possible combinations of the flow series resulting from 17 hydrological models with different spatial scales, structures, concepts and approaches (i.e., model-driven and data-driven). Subsequently, the members (models) of the best average ensembles according to each metric were valued using Average Bayesian Model BMA method to know their participation or weight within these best-ensembles. Knowing weights, three new assemblies were generated that evaluated in their performance against the previous average assemblies and the best models for both time scales at the basin scale and its sub-basins. On the other hand, the BMA allowed establishing that local-scale models (SWAT and deep learning algorithm) have greater importance in the improvement of discharge since their ensemble's weights were higher than the other evaluated models. Finally, by modifying the weights previously obtained, the ensemble uncertainty range was estimated and evaluated it by three criteria.

The performance of the three ensembles that consider BMA's weights according to the deterministic and probabilistic metrics increased performance of flow estimation and the uncertainty range evaluated in the three best-ensembles was reduced with probabilistic metric.

Keywords: hydrological ensemble prediction, BMA, Prado, Deep Learning

Tabla de Contenido

AGRADECIMIENTOS.....	2
RESUMEN	3
ABSTRACT	4
LISTA DE FIGURAS.....	7
LISTA DE TABLAS.....	10
1. INTRODUCCIÓN	11
2. PREGUNTA MOTIVADORA DEL ESTUDIO	13
3. OBJETIVOS	13
3.1. OBJETIVO GENERAL.....	13
3.2. OBJETIVOS ESPECÍFICOS.....	13
4. ANTECEDENTES	14
5. METODOLOGÍA DE CONSTRUCCIÓN Y EVALUACIÓN DEL ENSAMBLE HIDROLÓGICO	19
5.1. ELEMENTOS CONSTITUTIVOS DE ENSAMBLES (MODELOS HIDROLÓGICOS).....	24
5.2. CONSTRUCCIÓN DEL ENSAMBLE HIDROLÓGICO	42
6. CASO DE ESTUDIO	50
6.1. MORFOMETRÍA DE LAS SUBCUENCAS	51
6.2. SUELOS	55
6.3. COBERTURAS DE SUELO	57
6.4. CARACTERIZACIÓN HIDROCLIMATOLÓGICA	59
7. RESULTADOS Y ANÁLISIS	70
7.1. MODELOS HIDROLÓGICOS LOCALES.....	70
7.2. MODELOS HIDROLÓGICOS REGIONALES.....	84
7.3. MODELOS HIDROLÓGICOS GLOBALES	84
7.4. EVALUACIÓN DEL DESEMPEÑO DE CADA MIEMBRO DEL ENSAMBLE	87
7.5. ANÁLISIS DE LA CANTIDAD DE MIEMBROS FRENTE AL DESEMPEÑO DE LOS 50 MEJORES ENSAMBLES PROMEDIO SEGÚN MÉTRICA KGE Y CRPS	89
7.6. DESEMPEÑO DE LOS ENSAMBLES PROMEDIO SEGÚN EL NÚMERO DE MIEMBROS	91
7.7. COMPORTAMIENTO DE LOS MEJORES ENSAMBLES PROMEDIO.....	94
7.8. PARTICIPACIÓN DE TODOS LOS MODELOS O MIEMBROS FRENTE AL MEJOR ENSAMBLE PROMEDIO SEGÚN CRPS, NSE Y KGE.	96
7.9. ¿MEJORA LA ESTIMACIÓN DE LOS CAUDALES CON EL MEJOR ENSAMBLE?	99

7.10.	ANÁLISIS Y EVALUACIÓN DE LA INCERTIDUMBRE DEL ENSAMBLE.....	104
8.	CONCLUSIONES	108
9.	LIMITACIONES DEL TRABAJO DESARROLLADO	111
10.	INTERROGANTES ADICIONALES O PERSPECTIVAS DE INVESTIGACIÓN.....	111
11.	BIBLIOGRAFÍA.....	113
12.	ANEXO 1. LEYENDA DEL MAPA DE SUELOS	120
13.	ANEXO 2. HIDRÓGRAFAS DE MODELOS ESCALA DIARIA Y MENSUAL.....	122
14.	ANEXO 3. HIDRÓGRAFA DE NME ESCALA DIARIA Y MENSUAL	134

LISTA DE FIGURAS

Figura 5-1.	Metodología general de construcción de un ensamble hidrológico multimodelo con evaluación de incertidumbre	20
Figura 5-2.	Adaptación de la metodología de construcción del ensamble hidrológico multimodelo aplicada al caso de estudio cuenca del río Prado.	21
Figura 5-3.	Esquema general modelos locales e información de entrada	25
Figura 5-4.	Entradas y salidas del modelo SWAT	26
Figura 5-5.	Campo de precipitación distribuida tomada del proyecto Earth2Observe	28
Figura 5-6.	Ventana de configuración y simulación de SWAT	29
Figura 5-7.	Resultado análisis de sensibilidad de 48 parámetros en SWAT-CUP.....	31
Figura 5-8.	Arquitectura Red Neuronal Artificial tipo creada para el modelo DL-Keras con entradas De Vos y Brochero.....	34
Figura 5-9.	Estructura de una red neural artificial.....	35
Figura 5-10.	Ejemplo del proceso de entrenamiento de Keras en R.	36
Figura 5-11.	Ejemplo serie de caudales, precipitación y evapotranspiración escalada	36
Figura 5-12.	Esquema del modelo hidrológico VIC.....	38
Figura 5-13.	Esquema funcionamiento modelo MESH.....	39
Figura 5-14.	Malla modelo GLDAS 0.25° (Izq.) y malla modelos regionales y globales provenientes del earth2observe (Der.).....	41
Figura 5-15.	Esquema general de un ensamble hidrológico	43
Figura 5-16.	Ejemplo intervalo de incertidumbre del 90% de un mejor ensamble ME	48
Figura 6-1.	Localización caso de estudio cuenca del río Prado	50
Figura 6-2.	Cuencas definidas del caso de estudio según estaciones hidrométricas.....	52
Figura 6-3.	MDE y delimitación de las subcuencas.....	54
Figura 6-4.	Curvas hipsométricas de la cuenca del río Prado y sus subcuencas Cunday y San Pablo Prado.....	55
Figura 6-5.	Mapa de suelos	56
Figura 6-6.	Mapa de coberturas vegetales Corine Land Cover.....	58
Figura 6-7.	Estaciones climatológicas para precipitación.....	60
Figura 6-8.	Precipitación media mensual multianual y su valor promedio, para el periodo de 1981-2012.	61
Figura 6-9.	Distribución espacial de la precipitación promedio multianual (mm) (Isoyetas)	62
Figura 6-10.	Temperatura mínima, media y máxima de las estaciones Pst de Monta y Lozanía, a escala mensual	63
Figura 6-11.	Evapotranspiración potencial mensual para cuenca del río Prado y sus dos subcuencas. Periodo 1981-2012	64
Figura 6-12.	Serie de caudales observados estaciones Cunday (arriba), San Pablo (centro) periodo 1981-2011 y Boquerón (abajo) periodo 1981-2002.....	65
Figura 6-13.	Curvas duración de caudales de registros diarios y mensuales de las estaciones Pte. Cunday, San Pablo y Boquerón	67
Figura 6-14.	Diagrama de cajas caudales diarios y mensuales estaciones Cunday, San Pablo (1981-2011) y Boquerón (1981-2002).....	68
Figura 7-1.	Caudales mensuales SWAT Cuenca Cunday. a) hidrógrafa b) curva acumulada de caudales y c) dispersión	71
Figura 7-2.	Caudales mensuales SWAT Cuenca San Pablo. a) hidrógrafa b) curva acumulada de caudales y c) dispersión	72

Figura 7-3.	Caudales mensuales SWAT Cuenca Prado. a) hidrógrafa b) curva acumulada de caudales y c) dispersión	73
Figura 7-4.	Precipitación total promedio multianual determinada por SWAT. Pin-situ (Izq) Pdistri (Der)	75
Figura 7-5.	Caudales mensuales Keras cuenca Cunday. a) hidrógrafa b) curva acumulada de caudales y c) dispersión	77
Figura 7-6.	Caudales mensuales Keras cuenca San Pablo a) hidrógrafa b) curva acumulada de caudales y c) dispersión	78
Figura 7-7.	Caudales mensuales Keras cuenca Prado a) hidrógrafa b) curva acumulada de caudales y c) dispersión	79
Figura 7-8.	Series simuladas para cada cuenca del mejor modelo en Keras y en SWAT a escala mensual.....	82
Figura 7-9.	Series simuladas para cada cuenca del mejor modelo en Keras y en SWAT escala diaria	83
Figura 7-10.	Diagrama de cajas modelos MESH y VIC escala diaria.....	84
Figura 7-11.	Diagrama de cajas modelos globales escala diaria cuenca Cunday	85
Figura 7-12.	Diagrama de cajas modelos globales escala diaria cuenca San Pablo	85
Figura 7-13.	Diagrama de cajas modelos globales escala diaria cuenca Prado	86
Figura 7-14.	Diagrama de cajas modelos globales 0.25° escala diaria	86
Figura 7-15.	Cantidad de miembros y comportamiento de las métricas KGE vs CRPS en 50 ME promedio. Arriba Cunday, centro San Pablo y Abajo Prado.	90
Figura 7-16.	Desempeño de todos los ensambles promedio según KGE (arriba), CRPS (centro) y NSE (abajo) frente al número de miembros en las cuencas Cunday (Izq.), cuenca San Pablo (centro) y cuenca Prado (Der.). Escala diaria.....	92
Figura 7-17.	Desempeño de todos los ensambles promedio según KGE (arriba), CRPS (centro) y NSE (abajo) frente al número de miembros en las cuencas Cunday (Izq.), cuenca San Pablo (centro) y cuenca Prado (Der.). Escala Mensual.....	93
Figura 7-18.	Mejores Ensambls según KGE, NSE y CRPS escala diaria cuenca Cunday	94
Figura 7-19.	Mejores Ensambls según KGE, NSE y CRPS escala diaria cuenca San Pablo	95
Figura 7-20.	Mejores Ensambls según KGE, NSE y CRPS escala diaria cuenca Prado	95
Figura 7-21.	Esquema radial de participación de los modelos dentro del mejor ensamble	97
Figura 7-22.	Pesos BMA mejor ensamble escala diaria	98
Figura 7-23.	Pesos BMA mejor ensamble escala mensual	99
Figura 7-24.	Evaluación del desempeño del mejor modelo, mejor ensamble promedio y nuevo mejor ensamble en las tres cuencas a escala diaria y periodo de calibración.....	101
Figura 7-25.	Evaluación del desempeño del mejor modelo, mejor ensamble promedio y nuevo mejor ensamble en las tres cuencas a escala diaria y periodo de validación.....	101
Figura 7-26.	Evaluación del desempeño del mejor modelo, mejor ensamble promedio y nuevo mejor ensamble en las tres cuencas a escala mensual y periodo de calibración.....	102
Figura 7-27.	Evaluación del desempeño del mejor modelo, mejor ensamble promedio y nuevo mejor ensamble en las tres cuencas a escala mensual y periodo de validación	102
Figura 7-28.	Observados y mejor ensamble (NME~KGE, NME~NSE y NME~CRPS) Cuenca San Pablo escala diaria periodo 1981-2002 de calibración.	103
Figura 7-29.	Franja de incertidumbre del NME~CRPS cuenca Prado año 1991.	104
Figura 7-30.	Franja de incertidumbre cuenca Cunday del NME~CRPS año 1991	105
Figura 7-31.	Franja de incertidumbre mayo de 1991 cuenca Cunday escala diaria	106
Figura 13-1.	Series de caudales de modelos globales escala diaria cuenca Cunday periodo de 1981-2011	122

Figura 13-2.	Series de caudales modelos globales escala diaria cuenca San Pablo periodo de 1981-2011	123
Figura 13-3.	Series de caudales modelos globales escala diaria cuenca Prado periodo de 1981-2002	124
Figura 13-4.	Series de caudales de modelos regionales y locales escala diaria cuenca Cunday periodo de 1981-2011	125
Figura 13-5.	Series de caudales modelos regionales y locales escala diaria cuenca San Pablo periodo de 1981-2011	126
Figura 13-6.	Series de caudales modelos regionales y locales escala diaria cuenca Prado periodo de 1981-2002.....	127
Figura 13-7.	Series de caudales de modelos globales escala mensual cuenca Cunday periodo 1981-2011	128
Figura 13-8.	Series de caudales modelos globales escala mensual cuenca San Pablo periodo 1981-2011	129
Figura 13-9.	Series de caudales modelos globales escala mensual cuenca Prado periodo 1981-2002	130
Figura 13-10.	Series de caudales de modelos regionales y locales escala mensual cuenca Cunday periodo 1981-2011.....	131
Figura 13-11.	Series de caudales modelos regionales y locales escala mensual cuenca San Pablo periodo 1981-2011.....	132
Figura 13-12.	Series de caudales modelos regionales y locales escala mensual cuenca Prado periodo 1981-2002.....	133
Figura 14-1.	Observados y nuevo mejor ensamble (NME~KGE, NME~NSE y NME~CRPS) Cuenca Cunday escala diaria -periodo de calibración 1981-2002	134
Figura 14-2	Observados y nuevo mejor ensamble (NME~KGE, NME~NSE y NME~CRPS) Cuenca San Pablo escala diaria periodo de calibración 1981-2002	135
Figura 14-3.	Observados y nuevo mejor ensamble (NME~KGE, NME~NSE y NME~CRPS) Cuenca Prado escala diaria periodo de calibración 1981-1996	136
Figura 14-4.	Observados y nuevo mejor ensamble (NME~KGE, NME~NSE y NME~CRPS) Cuenca Cunday escala mensual periodo de calibración 1981-2002.....	137
Figura 14-5.	Observados y nuevo mejor ensamble (NME~KGE, NME~NSE y NME~CRPS) Cuenca San Pablo escala mensual periodo de calibración 1981-2002	138
Figura 14-6.	Observados y nuevo mejor ensamble (NME~KGE, NME~NSE y NME~CRPS) Cuenca Prado escala mensual periodo de calibración 1981-1996.....	139

LISTA DE TABLAS

Tabla 5-1.	Combinaciones posibles tomando desde 2 y 17 miembros.....	22
Tabla 5-2.	Parámetros definitivos durante la calibración en SWAT-CUP	32
Tabla 5-3.	Resultados NSE para calibración y validación en SWAT-CUP.	33
Tabla 5-4.	Resultados proceso de calibración y validación para DL-Keras.....	37
Tabla 6-1.	Parámetros morfométricos de las áreas de estudio en cuenca del río Prado...	54
Tabla 6-2.	Distribución de suelos basado en el tipo de paisaje y clima.....	57
Tabla 6-3.	Estaciones climatológicas cuenca río Prado	59
Tabla 6-4.	Estaciones hidrométricas dentro de la cuenca Prado	64
Tabla 7-1.	Desempeño modelos SWAT Pin-situ y SWAT Pdistri	74
Tabla 7-2.	Desempeño modelos DL KerasDeVos y KerasBrochero	80
Tabla 7-3.	Desempeño cada modelo vs los observados escala diaria periodo de calibración	88
Tabla 7-4.	Desempeño de cada modelo vs los observados escala mensual periodo de calibración.....	88
Tabla 7-5.	Resultado evaluación de la incertidumbre por métricas en las tres cuencas para los tres nuevos mejores ensamblajes NME según KGE, NSE y CRPS para los periodos de calibración y validación a escala diaria.	107
Tabla 7-6.	Resultado evaluación de la incertidumbre por métricas en las tres cuencas para los tres nuevos mejores ensamblajes NME según KGE, NSE y CRPS para los periodos de calibración y validación a escala mensual.....	107

1. INTRODUCCIÓN

La modelación hidrológica ha sido una herramienta importante en múltiples propósitos como pronósticos de inundaciones y sequías, incremento del conocimiento del ciclo hidrológico y la cuantificación del recurso hídrico, entre otras (Beck et al., 2017). Respecto a los caudales, en el mundo, se han realizado esfuerzos para que su estimación sea cada vez más exacta, pero las diferentes fuentes de incertidumbre inciden en sus resultados, debido a que los modelos no pueden llegar a caracterizar todos los procesos del ciclo hidrológico (Fenicia et al., 2008).

Una de las estrategias planteadas tanto para enfrentar la incertidumbre como para mejorar la estimación de los caudales ha sido el desarrollo de ensambles hidrológicos. El concepto de ensamble está construido en la noción básica de que la combinación de múltiples puntos de vista conduce a mayor exactitud de la realidad (Surowiecki, 2004). La implementación de esta técnica se enriquece por la diversidad de sus miembros heterogéneos (i. e., diferentes modelos hidrológicos y enfoques), aprovechando las fortalezas y debilidades de cada uno de ellos para estimar de una mejor manera los caudales.

La mayoría de ensambles hidrológicos en la literatura han sido construidos con miembros de su misma naturaleza y diferentes forzamientos o sus alteraciones (i. e., datos de entrada). No obstante, nuevas formas de construir ensambles, como múltiples estructuras (Arboleda-Obando et al., 2018) y múltiples análisis (Bowler et al., 2007) han reportado mejoras en la estimación de caudales. Ahora bien, estas estrategias de construcción no son excluyentes entre sí. Es decir, un ensamble multimodelo se puede analizar de varias maneras utilizando modelos estructuralmente disímiles con iguales o diferentes forzamientos.

La aproximación de ensambles multiestructura, ha abierto la posibilidad de incorporar modelos direccionados por datos (e. g., redes neuronales artificiales, *support vector machine*, *fuzzy logic*, entre otras) que han sido ampliamente usados para estimación de caudales (Abrahart et al., 2012; Brochero, 2013; De Vos, 2013). Aunque estas nuevas técnicas han sido incorporadas en la generación de ensambles hidrológicos, sus fortalezas no han sido combinadas con las de los modelos hidrológicos tradicionales.

Este trabajo de grado aborda la mejora en la estimación de caudales mediante la construcción de ensambles hidrológicos multimodelo, con la particularidad de que no solamente utiliza varios modelos hidrológicos similares, sino que ellos poseen diferentes estructuras y escalas, es decir, son modelos desarrollados a escala global, regional y local; modelos conceptuales,

modelos basados en datos, modelos de superficie terrestre a escalas espaciales agregadas y/o distribuidas, con escalas temporales diarias y mensuales. Este enfoque fue aplicado al caso de estudio, la cuenca del río Prado y a sus subcuencas Cunday y San Pablo. De esta manera se conocerá sí para el caso de estudio el ensamble hidrológico mejora la estimación de los caudales.

Los modelos hidrológicos utilizados fueron 17, para ser más específicos, doce de ellos fueron modelos hidrológicos globales y regionales, utilizados en el proyecto earth2Observe¹ (“Global Earth Observation for Integrated Water Resources Assessment”) aplicado a la macrocuenca Magdalena-Cauca, otro modelo global correspondió a GLDAS (*Global Land Data Assimilation System*) de NASA *Earth Sciences Data and Information Services Center* (GES DISC), y los últimos cuatro modelos locales fueron desarrollados plenamente durante el trabajo de grado. Ellos son SWAT con dos conjuntos de datos de entrada diferentes y un modelo tipo Deep Learning (redes neuronales profundas) mediante la librería Keras² con diferentes entradas.

El orden del documento pretender mostrar el propósito principal del trabajo de grado y el desarrollo de los tres objetivos específicos. Primero se señalan los antecedentes de los ensambles hidrológicos. Luego se describe la metodología sin haber mencionado el caso de estudio con el fin de orientar la posibilidad de replicarla sin estar sujeta al área de interés de este trabajo. Enseguida se presentan los resultados y sus análisis para finalizar en las conclusiones. Se agregaron resultados como anexo para hacer más sencillo ese apartado.

¹ Earth2Observe: consistió en investigar cómo es el aporte de uso de datos de diferentes forzamientos y de un ensamble hidrológico en esta macrocuenca Magdalena-Cauca, a la generación de información más confiables para el proceso de toma de decisiones. Lo anteriormente mencionado era realizado mientras se investigaba la disponibilidad del recurso hídrico y la variabilidad hidrológica. Los resultados están visibles en el portal <https://wci.earth2observe.eu>

² Keras: s una herramienta o librería de código abierto desarrollada en lenguaje Python para programación de redes neuronales profundas de manera ágil, modular, entre otras características.

2. PREGUNTA MOTIVADORA DEL ESTUDIO

¿Contribuirá la metodología de ensamble hidrológico en la estimación de caudales a escala diaria y mensual cuando sus modelos (miembros) son tanto modelos basados en procesos como modelos basados en datos?

3. OBJETIVOS

3.1. OBJETIVO GENERAL

Construir un ensamble hidrológico multimodelo y multienfoque a escala diaria y mensual para mejorar la estimación de caudales en la cuenca del río Prado

3.2. OBJETIVOS ESPECÍFICOS

- Desarrollar modelos hidrológicos (miembros) locales de la cuenca del río Prado mediante el algoritmo Deep Learning (modelo basado en datos) y el modelo SWAT a escala diaria y mensual (modelo basado en procesos).
- Conformar los demás miembros (regionales y globales) del ensamble a partir de modelos disponibles en el portal del proyecto earth2Observe.
- Construir el ensamble hidrológico multimodelo y evaluar su desempeño en la estimación de caudales.

4. ANTECEDENTES

Los diferentes tipos y clasificaciones de modelos hidrológicos han buscado simular los procesos del ciclo hidrológico a lo largo y ancho del planeta, pero gran parte de estos procesos son complejos y no se entienden con completo detalle (Xu, 2002). Beven (1989) menciona que los modelos no pueden representar totalmente la realidad, por ende los resultados de las modelaciones llevan consigo un grado de incertidumbre.

En la literatura se han reconocido principalmente tres tipos de fuentes de incertidumbre: (a) en los datos de entrada, (b) paramétrica y (c) estructural del modelo (McMillan et al., 2012). Estas fuentes de incertidumbre se deben a las siguientes consideraciones: (a) aunque cada día se recolectan más datos experimentales, como caudales, niveles del agua, sedimentos, etc., es aún difícil asegurarse que todo sea medido en todo momento y que sea medido en las escalas de ocurrencia de cada proceso hidrológico. (b) los parámetros de los modelos casi nunca corresponden a una variable observable del ciclo hidrológico, no hay conjunto de parámetros único que ofrezca la mejor respuesta del modelo, es decir la propiedad de equifinalidad (Beven, 2001) y (c) existen diferentes maneras de abstraer la realidad al modelo, derivándolos de procesos físicos, evaluaciones empíricas que usan variadas suposiciones y/o simplificaciones aplicadas a diferentes escalas.

Con el fin de cuantificar y comunicar las incertidumbres, como sugiere Krzysztofowicz (2001) se ha incursionado en la modelación a través de ensambles, porque se dejan atrás los resultados determinísticos de las modelaciones para ofrecer resultados probabilísticos que permiten explorar los tres principales tipos de incertidumbres (Dance and Zou, 2010; Thiboult et al., 2016).

Un ensamble en general es un conjunto de varios miembros (modelos) en el cual cada miembro representa un posible estado del sistema o modelo evaluado. El ensamble, dicho de otra manera, se convierte en una función de probabilidad que recopila la incertidumbre del sistema (Wilks, 1995). En hidrología sería un conjunto de varios resultados de simulaciones hidrológicas (particularmente caudales) tratadas para mejorar una estimación, predicción y/o pronóstico.

Luego de los primeros desarrollos en ensambles se ha generado una premisa fundamental para incentivar el uso del método: el comportamiento y/o predicción del ensamble es superior

al de cada uno de los miembros que lo constituyen (Bowler et al., 2007; Regonda et al., 2006; Roulin and Vannitsem, 2005; Toth and Kalnay, 1997).

En la modelación por ensambles, la construcción de los miembros es parte importante. Desde su inicio, la generación de perturbaciones en las condiciones iniciales producían varios resultados que se convertirían en miembros (Palmer et al., 1997). Para generar las perturbaciones han aplicado metodologías como vectores singulares (Palmer et al., 1997), vectores Breeding (Toth and Kalnay, 1997), el ampliamente difundido Filtro Kalman (Wei et al., 2006) y su derivación Generador Kalman (Nowak, 2009).

No solo mediante perturbaciones iniciales se generan miembros de un ensamble, sino también a través de la utilización de diferentes modelos (ensamble multimodelo³ (De Vos, 2013; García-Moya et al., 2011; Qu et al., 2017), múltiples forzamientos⁴ (Cluckie et al., 2006; Fundel et al., 2013; García-Moya et al., 2007), múltiples estructuras⁵ (Arboleda-Obando et al., 2018) y múltiples análisis⁶ (Bowler et al., 2007).

Puntualizando en los ensambles multimodelo y multiestructura, esta metodología recoge la idea de que todos los modelos poseen fortalezas y debilidades frente a otros modelos (Kan et al., 2015): esas diferentes características generan la mejor propiedad de la estrategia multimodelo, la diversidad. Utilizada por Brochero (2013) y Sharma et al. (2019) para mejorar la predicción de los ensambles. Por ejemplo, dentro de un mismo ensamble de estimación de escorrentía, un modelo puede simular en mejor manera los caudales en periodos secos, otro modelo los caudales medios, otro caracteriza mejor la percolación, otro modelo representa mejor los caudales máximos, etc., así el ensamble se enriquece de la diversidad de los modelos y se acerca a la identificación de las incertidumbres estructural y paramétrica de los modelos.

³ Multimodelo: uso de más de un modelo hidrológico de similar estructura.

⁴ Multiforzamiento: uso de diferentes forzamientos para generar diferentes resultados con un mismo modelo o con varios modelos.

⁵ Multiestructura: es el uso de un ensamble multimodelo en donde la estructura de los modelos es diferente.

⁶ Multianálisis: cuando el ensamble, sin importar el tipo de ensamble se evalúa utilizando diferentes métricas determinísticas o probabilísticas.

El uso de ensambles hidrológicos multimodelo y multiestructura ha ido creciendo, encontrándose ensambles: [1] con modelos hidrológicos distribuidos y agregados (Seiller et al., 2017; Velázquez et al., 2011); [2] de origen conceptual y físicamente basado (Li et al., 2016; Thapa et al., 2017); [3] distribuidos- acoplados (Bohn et al., 2010; Sharma et al., 2019); [4] únicamente con modelos basados en datos tipo Redes Neuronales Artificiales (RNA) (Regonda et al., 2006); [5] modelo agregado de evento y modelos globales a escala 0.7° (Marty et al., 2013); y [6] únicamente modelos globales (Iversen et al., 2011). Predominando el uso de modelos hidrológicos conceptuales y físicamente basados y la no mezcla de estos modelos con los modelos basados en datos.

Deteniéndose ahora en un caso particular de la modelación hidrológica, cabe señalar que, tanto este tipo de modelación, como el desarrollo de ensambles hidrológicos se han volcado al uso de nuevos sistemas computacionales cómo la inteligencia artificial (*Machine Learning - ML*) (Khan and Coulibaly, 2006). Esta técnica computacional ha desarrollado algoritmos para aprender, inferir, encontrar patrones y predecir a partir de información suministrada en el proceso de entrenamiento, que es más conocido como *data-driven*, es decir modelos basados en datos. A partir de un tipo de aprendizaje (supervisado, no supervisado o por refuerzo), el algoritmo tiene capacidad de adaptarse a nuevas circunstancias y extrapolar patrones de comportamiento (Abrahart et al., 2012). En hidrología los algoritmos ML se han utilizado para la identificación de datos atípicos, descubrir relaciones entre variables de diferentes orígenes (e. g., vegetación, caudales, precipitación, sociales), identificación de expresiones matemáticas o ecuaciones, la predicción de caudales en ríos basados en condiciones climáticas y condiciones geográficas.

El algoritmo de ML ampliamente utilizado ha sido las RNA, tal como lo evidencia una revisión bibliográfica en donde el número de publicaciones de ejercicios de modelación lluvia-escorrentía con esta técnica han pasado de diez publicaciones al año para 1992 a 90 publicaciones en 2009 (Abrahart et al., 2012). De especial auge dentro de ML es la técnica de RNA llamada *Deep Learning* (DL) que consiste en un conjunto de algoritmos que abstraen patrones a partir de datos usando arquitecturas compuestas (jerárquicamente capas de neuronas artificiales) de transformaciones no lineales múltiples.

Dentro de algunos usos comunes de las RNA y DL se encuentra el pronóstico de precipitaciones que luego alimentan: modelos determinísticos lluvia-escorrentía (Toth et al., 2000), pronóstico hidrológico sin ensambles (Burn et al., 1999), modelos de pronóstico

hidrológico por ensambles (Vie et al., 2012), estimación de variables de recursos hídricos (Maier and Dandy, 2000); agrupación de modelos lluvia-escorrentía para conformar un ensamble (Jeong and Kim, 2005; Kan et al., 2015), estimación de la incertidumbre de modelos (Solomatine and Shrestha, 2009), predicción de niveles de inundación en área urbana (Assem et al., 2017), predicciones de lluvias en los monzones de la India (Singh, 2013) y operación de modelos basados en datos para predecir la distribución de errores (Solomatine and Shrestha, 2009).

De vos (2013) creó un modelo lluvia-escorrentía por medio de DL usando un algoritmo tipo *Echo State Networks* (ESN), que es un tipo de red neuronal recurrente, en las mismas 12 cuencas de (Brochero, 2013) para comparar sus resultados con otros algoritmos tradicionales de *Feed-forward Network FFN*. En esa investigación se concluye que ESN son una alternativa válida para el desarrollo de modelos lluvia-escorrentía obteniendo mejores y fiables resultados, comparados con métodos clásicos de ML.

Deep Learning tiene la habilidad de proveer una eficiente interpolación multidimensional que trata con múltiples escalas e información heterogénea (Lecun et al., 2015; Mallat, 2016). Similar a la heterogeneidad de los procesos hidrológicos lo que genera oportunidades para su uso en esta área (Marçais and de Dreuzy, 2017). Una de las aplicaciones que ha tenido el algoritmo DL ha sido en la reducción del sesgo y mejora de la exactitud de la estimación de precipitación por imágenes satelitales (Tao et al., 2016).

A nivel local, en Colombia, el Grupo de Investigación en Ingeniería de los Recursos Hídricos (GIREH) de la Universidad Nacional de Colombia en los últimos años ha enfocado parte de sus labores en la modelación por ensambles, ejemplo de ello es la ejecución del proyecto de investigación internacional *earthH2Observe “Global Earth Observation for Integrated Water Resources Assessment”* (Schellekens et al., 2017) financiado por el Séptimo Programa Marco de la Comisión Europea, desarrollado en la macrocuenca Magdalena-Cauca, otro ejercicio fue la conformación de dos ensambles multimodelo y multiestructura de la subcuenca del río Sumapaz para predicción de caudales diarios basado en 11 modelos hidrológicos (Arboleda-Obando et al., 2018); y el tercer ejercicio fue la elaboración de un ensamble multimodelo (modelos globales y regionales) y multiforzamientos dentro de la macrocuenca Magdalena-Cauca a escala mensual para apoyar la administración del recurso hídrico mediante la estimación del índice de regulación hídrica (Rodríguez et al., 2019).

A nivel general, es reducida la cantidad de estudios de modelación hidrológica por ensambles para predicción de caudales utilizando algoritmos ML y casi nulo el uso de DL (Shen, 2018). ML ha demostrado tener una gran capacidad para modelación lluvia-escorrentía, pero pocas son las aplicaciones (o no hay) en donde se combinan las fortalezas de la modelación hidrológica convencional, con la modelación basada en datos, y aún menos las aplicaciones de técnicas sofisticadas y robustas como DL. Por lo tanto, se abre una puerta para elaborar ensambles hidrológicos utilizando algoritmos de DL junto a modelos convencionales, con fines de mejora en la predicción.

El ensamble en el cual se utiliza la estrategia multimodelo y multiestructura donde los modelos son basados en proceso y basados en datos se denomina en el presente trabajo como ensamble multienfoque.

5. METODOLOGÍA DE CONSTRUCCIÓN Y EVALUACIÓN DEL ENSAMBLE HIDROLÓGICO

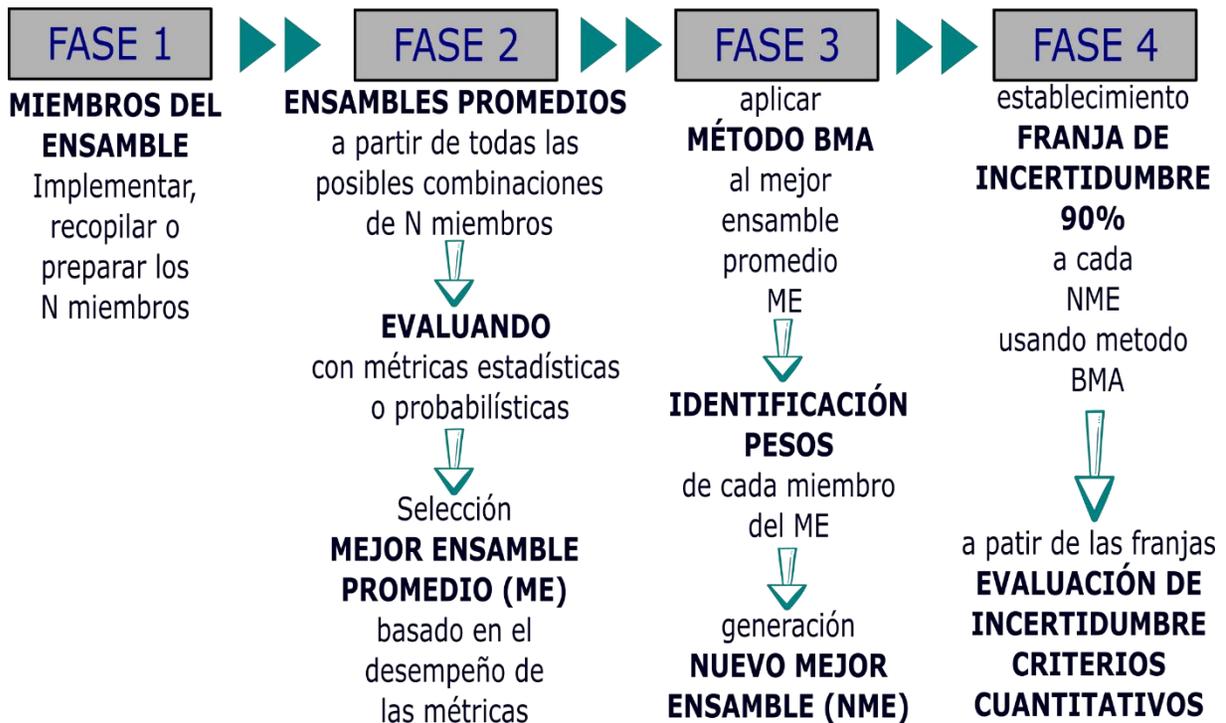
Indistintamente de la escala temporal (diaria y mensual) y de las subcuencas consideradas, la siguiente Figura 5-1 señala la metodología general para la construcción de un ensamble hidrológico multimodelo que incluya evaluación de incertidumbre. Allí, mediante cuatro fases se señalan los principales pasos a ejecutar comenzando con la Fase 1 en donde se obtienen los miembros que harán parte del ensamble. Para su obtención es posible que se requiere implementar desde cero los miembros o se tomen los resultados de modelos ejecutados por terceros.

Luego, la Fase 2 consiste en generar un primer ensamble “simple” que consiste en promediar todos los miembros en todas las posibles combinaciones que se puedan dar para los N miembros obtenidos anteriormente. Cada ensamble es evaluado por las métricas de interés del evaluador. Por cada métrica se determina un mejor ensamble promedio (ME).

Con las dos primeras fases se puede aseverar que se ha construido un ensamble, pero cabe recordar que la participación real de los miembros en la estimación de caudales no es igual. Por lo tanto, se da inicio a la Fase 3 en donde se aplica la metodología BMA para identificar la participación o peso de cada modelo dentro del ensamble. Posteriormente, utilizando los pesos obtenidos con BMA se recalcula la serie de caudales del ensamble que se denomina Nuevo Mejor Ensamble (NME). En este paso también se debe tener en cuenta que saldrán un NME por cada métrica que se utilice en el estudio.

Finalmente, se establece una franja de incertidumbre del 90% por cada NME determinado anteriormente. Para generar la franja se aplica una vez más el método BMA, ya que él genera múltiples posibles valores en los pesos de participación que permiten estimar múltiples valores de caudal por el grupo de miembros del ensamble. Una vez se tiene la franja se evalúa mediante ciertos criterios para llegar a identificar cuantitativamente que sucede con la incertidumbre del ensamble.

Figura 5-1. Metodología general de construcción de un ensamble hidrológico multimodelo con evaluación de incertidumbre

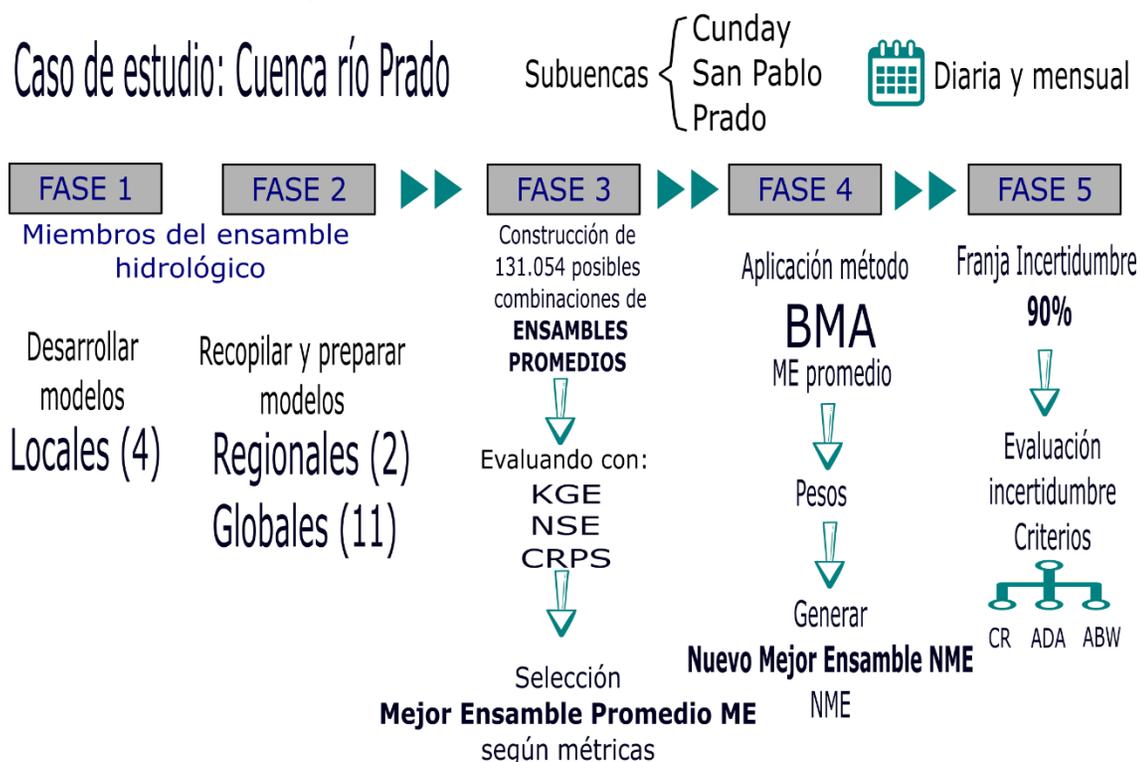


Fuente: Elaboración propia

A partir de la metodología general se generó una metodología específica que permitiera aplicarse al caso de estudio en la cuenca del río Prado, a sus dos subcuencas, que considere los tipos y cantidad de los modelos (miembros) globales, regionales y locales, las métricas a utilizar en la evaluación de desempeño, los criterios de evaluación de la incertidumbre, etc.

Esta metodología particular fue desarrollada en 5 fases continuas (ver Figura 5-2) para llegar a construir, evaluar el desempeño y evaluar la incertidumbre de un ensamble hidrológico multimodelo y multienfoque (ver numeral 5). Las fases desarrolladas fueron planteadas con miras a alcanzar los objetivos específicos trazados en el trabajo de grado. De ahí que la fase 1 atiende el primer objetivo, la fase 2 atiende el segundo objetivo y las fases 3 y 4 atienden el último objetivo. La fase 5 es una fase adicional y/o complementaria a la construcción del ensamble.

Figura 5-2. Adaptación de la metodología de construcción del ensamble hidrológico multimodelo aplicada al caso de estudio cuenca del río Prado.



Fuente: Elaboración propia

Fase 1. Modelos locales

Consistió en implementar cuatro modelos locales a escala de la cuenca del río Prado y sus dos subcuencas Cunday y San Pablo. Dos modelos son conceptualmente basados como lo es SWAT (*Soil Water and Assessment Tool*) en donde se utilizan dos forzamientos (precipitación) diferentes y los otros dos modelos mediante un modelo basado en datos tipo RNA-DL construido mediante la herramienta Keras utilizando dos tipos de entradas diferentes tomadas de dos autores que desarrollaron modelación hidrológica con RNA. Los detalles de los cuatro modelos se mencionan en el apartado 5.1.1.

Fase 2. Modelos regionales y globales

Recopilar las series de caudales resultantes, a escala diaria y mensual, de trece modelos. Doce de ellos fueron desarrollados (modelos regionales) y escalados (modelos globales) en el marco del proyecto earth2observe a una escala espacial de 10 km x 10 km dentro de la

macrocuena Magdalena-Cauca y el décimo tercer modelo fue desarrollado a nivel global a una escala espacial de 0.25°. Los nombres y particularidades de los modelos regionales y globales utilizados son detallados en los apartados 5.1.2 y 5.1.3.

Fase 3. Construcción ensamble promedio y evaluación del desempeño.

La construcción del ensamble inicia luego de la recopilación de las 17 series de caudales para cada cuena/subcuena y para cada escala temporal cuando se toman combinaciones de 2, 3, 4, ..., 16 o 17 modelos para promediarlos entre sí, sin distinguir su origen o desarrollo. El listado de posibles combinaciones se muestra en la Tabla 5-1 de la cual resultaron 131.054 ensambles promedio.

Tabla 5-1.		Combinaciones posibles tomando desde 2 y 17 miembros				
Combinaciones		Combinaciones		Combinaciones		
2	136	7	19.448	12	6.188	Total 131.054
3	680	8	24.310	13	2.380	
4	2.380	9	24.310	14	680	
5	6.188	10	19.448	15	136	
6	12.376	11	12.376	16	17	
				17	1	

Fuente: Elaboración propia

El paso siguiente fue evaluar el desempeño de cada uno de los 131.054 ensambles con sus series de caudales promediadas, frente a la serie de registros observados de cada cuena y cada escala temporal, mediante las métricas determinísticas NSE, KGE y la métrica probabilística CRPS, para obtener el mejor ensamble promedio según KGE (ME~KGE), el mejor ensamble promedio según NSE (ME~NSE) y el mejor ensamble promedio según CRPS (ME~CRPS).

En una actividad paralela se evaluó el desempeño de los 17 modelos individuales, mediante las métricas determinísticas NSE y KGE, con respecto a la serie de observados, con el fin de comparar su desempeño frente a los mejores ensambles promedios mencionados anteriormente.

Fase 4. Participación de los miembros en los mejores ensambles ME promedio y generación de un nuevo ensamble con pesos

La participación o peso de cada miembro dentro de los mejores ensambles anteriores es igual porque fueron generados con el promedio. A ellos se les realizó un análisis con el Modelo Bayesiano Promedio (en inglés BMA) con el paquete EBMAforecast (Montgomery et al., 2016) de R que permitió estimar los pesos ajustados de participación de cada modelo dentro del ensamble para los tres ME. En el análisis BMA la función de probabilidad (PDF) del ensamble es una PDF de pesos ponderados de cada uno de los miembros. De esta manera se puede obtener, por ejemplo, en un ensamble de cinco miembros unos pesos de la siguiente manera: 58%, 20%, 15%, 5% y 2%. De este modo, se consideran más ajustados los pesos con las condiciones de los modelos, por su diversidad es poco creíble que todos los modelos participen de igual manera en una nueva estimación.

Previo al análisis BMA se realizó la transformación de los datos utilizando la metodología de Johnson (Chou et al., 1998) ya que BMA requiere la información ajustada a la distribución normal.

Con los nuevos pesos conocidos de los ensambles se generan unas nuevas series de caudales con la participación correcta de cada modelo, haciendo un promedio ponderado para cada uno de los tres mejores ensambles. Estas nuevas series de caudales son denominadas nuevo mejor ensamble NME (NME~KGE, NME~NSE y NME~CRPS)

Fase 5. Estimación de la franja de incertidumbre y su evaluación

El paso adicional que se desarrolló fue la estimación de la franja o rango de incertidumbre junto a su evaluación mediante métricas de desempeño. Contribuyendo a no generar una respuesta determinística en la estimación de los caudales, con la estimación y evaluación de la incertidumbre se reconoce que no existe una única respuesta.

Para ello BMA volvió a ser la metodología utilizada para generar múltiples valores de la serie para cada paso de tiempo estableciendo un rango del 90% incertidumbre por cada ensamble.

Finalmente, mediante tres criterios o métricas se evaluó la incertidumbre. Ellas son CR: relación de contenidos, ADA: Promedio de la ampliación de la desviación y ABW: Promedio del ancho de la franja como lo utilizó (Dong et al., 2013).

5.1. ELEMENTOS CONSTITUTIVOS DE ENSAMBLES (MODELOS HIDROLÓGICOS)

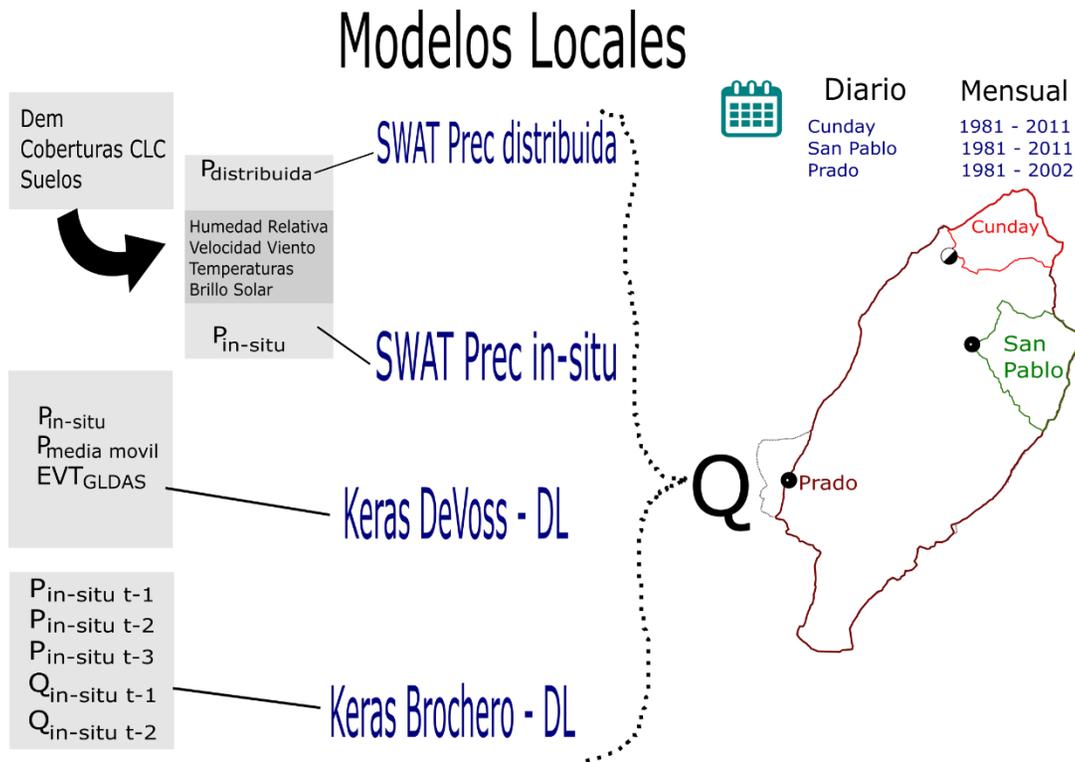
A continuación, se realiza la descripción de los modelos hidrológicos locales, regionales y globales que fueron usados en la construcción del ensamble hidrológico.

5.1.1. Modelos hidrológicos locales

Se les denomina locales a los modelos hidrológicos creados por el autor del presente trabajo de grado en un área de estudio igual a la cuenca río Prado (ver Figura 5-3). Esta figura muestra que los modelos se denominaron SWAT Precipitación in-situ, SWAT Precipitación distribuida⁷, KerasBrochero y KerasDeVos. Los dos modelos de SWAT requirieron una información cartográfica y otra información climatológica donde el uso de diferente precipitación permite implementar un modelo diferente. Los dos modelos de Keras tienen un enfoque de modelos basados en datos (i.e modelos de caja negra). En ellos las variables hidroclimatológicas de entrada son diferentes en los dos modelos en donde la estrategia de Brochero es utilizar caudales rezagados uno y dos pasos de tiempo y de precipitación rezagados uno, dos y tres pasos de tiempo mientras que la estrategia de De Vos es agregar la evapotranspiración potencial, la precipitación y una precipitación media móvil de 20 pasos de tiempo que sirve de indicador de humedad en la cuenca. El desarrollo de un ensamble con diferentes enfoques y estructuras de los modelos fue un elemento premeditado para generar diversidad en todos los miembros.

⁷ Precipitación distribuida: campo de precipitación generado en el proyecto earth2Observe mediante un extenso tratamiento de los datos observados in-situ del IDEAM y la posterior generación de la interpolación mediante Kriging Exernal Drift (KED) (Rodríguez et al., 2019).

Figura 5-3. Esquema general modelos locales e información de entrada



Fuente: Elaboración propia

5.1.1.1. Modelo SWAT

SWAT (*Soil Water and Assessment Tool*) (Arnold et al., 1998) es un modelo hidrológico físicamente basado, semidistribuido y continuo. Los creadores así lo definieron, sin importar cual es la finalidad del uso de SWAT que siempre el balance hídrico será el motor de todo lo que ocurra en la cuenca. Para ello, la conceptualización principal de SWAT es la consecución del balance hídrico tanto a nivel general, subcuencas y de subdivisión llamadas Unidades de Respuesta Hidrológica (en inglés *HRU*). Tales subdivisiones (semidistribución) de zonas similares o subáreas se conectan a los cauces a través de la fase de enrutamiento del ciclo hidrológico (Gassman et al., 2014). Las HRU y subcuencas benefician un incremento en la exactitud del modelo y una mejor descripción física de los procesos hidrológicos que ocurren en el balance hídrico, dado que la escorrentía es calculada considerando las diferencias de los suelos y sus coberturas dentro de las HRU.

A continuación, se presenta la ecuación de balance hídrico que usa el modelo SWAT (Neitsch et al., 2011)

$$SWt = SW0 + \sum (R \text{ day} - Q_{surf} - Ea - W_{seep} - Q_{gw}) \quad \text{Ecuación 5-1}$$

Donde:

SWt: contenido final de agua en el suelo (mm).

SW0: contenido inicial de agua del suelo en un día *i* (mm).

Rday: cantidad de precipitación en un día *i* (mm).

Qsurf: cantidad de escorrentía de la superficie en día *i* (mm)

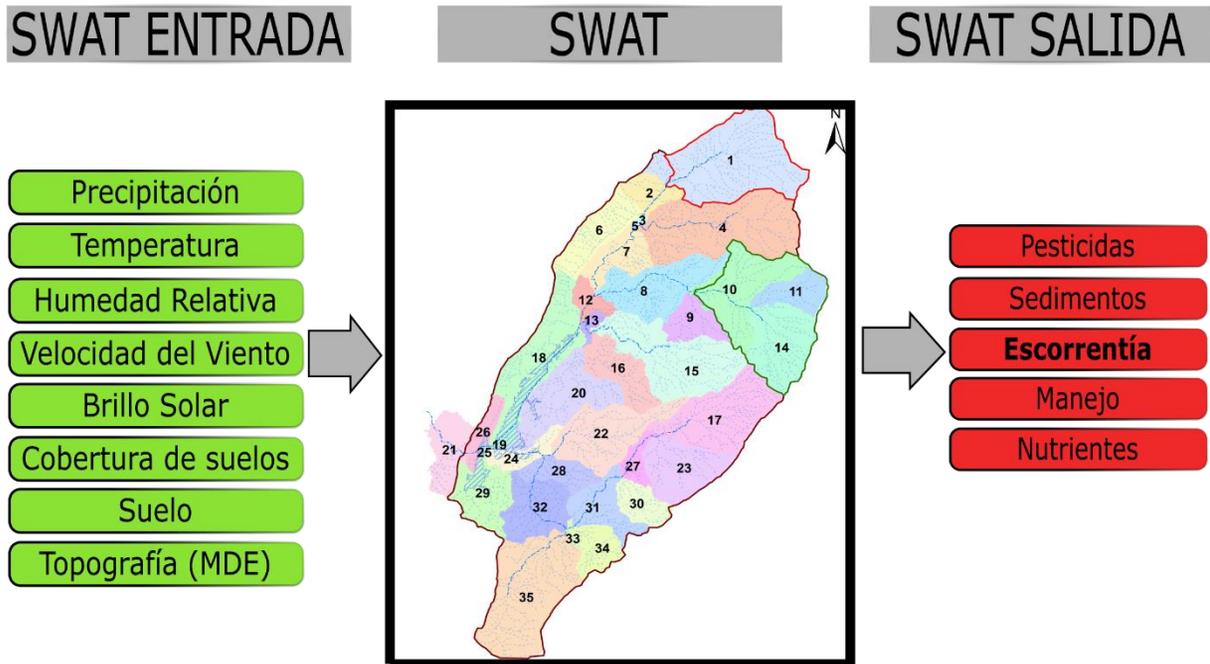
Ea: cantidad de evapotranspiración en día (mm).

Wseep: cantidad de agua que entra en la zona que percola en el perfil del suelo en día (mm).

Qgw: cantidad del flujo de retorno en un día (mm).

Subíndice *t*: tiempo en días

Figura 5-4. Entradas y salidas del modelo SWAT



Fuente: modificado de Heo et al (2008)

El modelo hidrológico SWAT fue creado a partir de otros modelos matemáticos, con la misión de ofrecer a los modeladores, autoridades e investigadores herramientas para la toma de

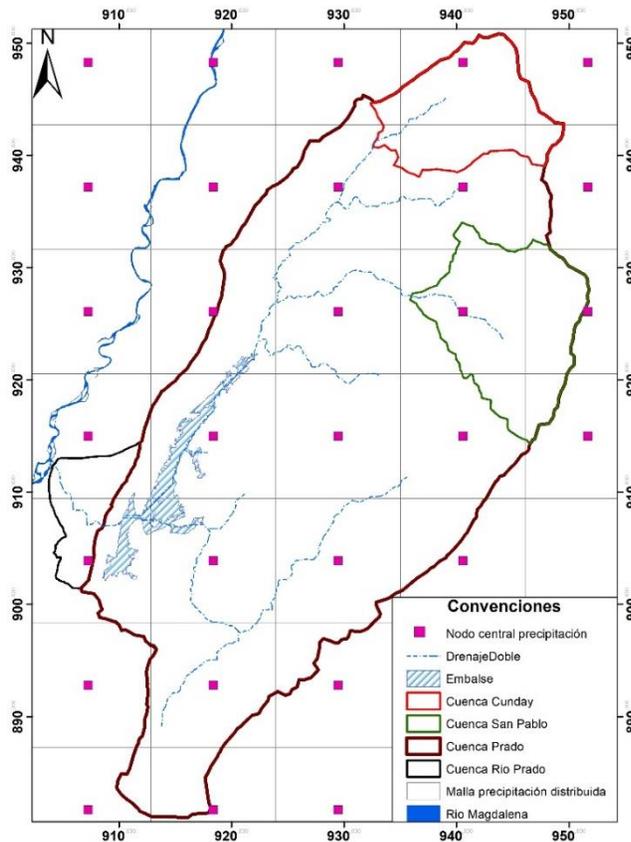
decisiones en áreas de disponibilidad de agua, impacto del manejo del agua, aporte de sedimentos, temperatura del suelo, contaminantes, riego, fertilización y crecimiento de cultivos para grandes cuencas (Arnold et al., 2012) donde se introducen los elementos cartográficos y climáticos de la parte izquierda de la Figura 5-4 para obtener los resultados de la derecha en la misma figura y que fueron mencionados anteriormente.

Las entradas del modelo SWAT para los dos modelos desarrollados fueron el modelo digital de elevación (MDE) a partir del cual se definieron las cuencas, el mapa de coberturas de suelos, el mapa de suelos, registros de 2 estaciones de temperatura, 2 estaciones de humedad relativa, 2 estaciones de brillo solar y 1 estación para velocidad del viento y 11 estaciones para la precipitación. Cuando los datos de lluvia son de los registros observados de las estaciones de la red del IDEAM sin transformaciones a campo de precipitación se le denomina al modelo SWAT Precipitación in-situ (Pin-situ). Si los registros de lluvia corresponden al campo de precipitación del proyecto earth2observe, que también provienen del IDEAM, el modelo se denomina SWAT Precipitación distribuida (Pdistri).

Precipitación distribuida (Pdistri)

La precipitación distribuida corresponde a un campo de precipitación diaria y mensual de escala 10 km x 10 km, elaborado y utilizado en el proyecto Earth2observe como forzamiento para los modelos hidrológicos allí implementados a partir de observaciones in -situ de estaciones del IDEAM. Este campo de precipitación es el resultado de interpolación con el método Kriging External Drift (KED) a partir de las estaciones con el 15% o menos de datos perdidos que fueron recortadas al periodo de tiempo 1981-2012. Se les realizó depuración rápida de datos atípicos y valores erróneos, ubicándolos mediante el diagrama de cajas y con filtros por probabilidad física de ocurrencia del evento, por ocurrencia de fenómeno climático (ENSO) y por correlación con otras estaciones (Rodriguez et al., 2019). Además, de un proceso de rellenado de datos fue realizado, de nombre tipo A, que tiene refuerzo por correlación con otras estaciones y por fuerza bruta, además de análisis de estadísticos, curvas de duración de caudales, análisis de funciones de probabilidad, y cálculo de valores promedio mensuales. Las celdas del campo de lluvias se muestran en la Figura 5-5.

Figura 5-5. Campo de precipitación distribuida tomada del proyecto Earth2Observe



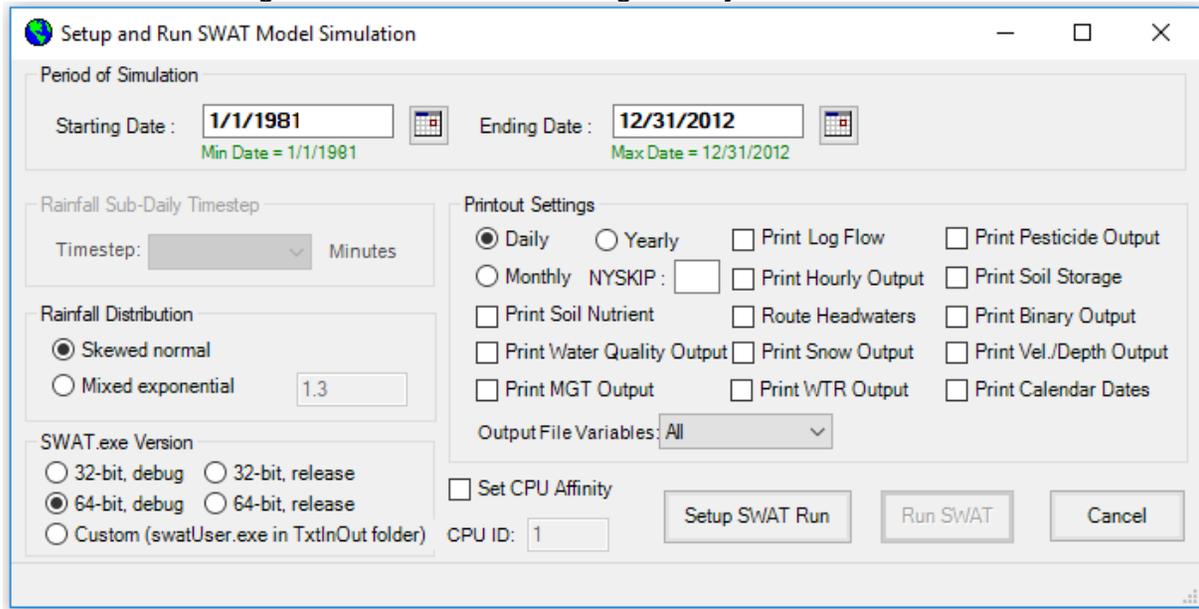
Fuente: Elaboración Propia

La configuración de la cuenca del río Prado para ambos modelos fue la misma, se generaron 35 subcuencas desde 6.30 ha hasta 13720 ha con un promedio de 4670 ha y algunas de ellas cierran o su punto más bajo coincide con las estaciones hidrométricas que se definieron en el caso de estudio.

Por otro lado, considerando las combinaciones de las 21 coberturas, 16 tipos de suelos, 3 categorías de pendientes (10%, 30% y superior) se sobrepusieron para definir 1074 HRU con áreas desde 0.09 ha (0.0009 km²) hasta 3276.8 ha (32.8 km²) y un promedio de 152.5 ha (1.52 km²). Contrastando el tamaño de HRU con otros estudios se encuentra que (Ha et al., 2017) en Vietnam generó en una cuenca de 6300 km² 109 subcuencas y 7909 HRU (promedio 0.8 km²), (Ghaffari et al., 2010) en Irán 4354 km² para 63 subcuencas y 602 HRU (promedio 7.2 km²), (Grath, 2016) 988.1 km² para 30 subcuencas y 665 HRU (promedio 1.48 km²) y (Weber and Ocampo, 2019) en Córdoba, Argentina simuló 592.7 km² para 67 subcuencas 1911 HRU (promedio 0.3 km²).

La Figura 5-6 presenta la ventana previa para iniciar la simulación de SWAT. En ella se observa el periodo de simulación, la escala de tiempo, la versión del procesador que posee la máquina en la que corre el modelo, entre otras opciones.

Figura 5-6. Ventana de configuración y simulación de SWAT



Fuente: Elaboración Propia

Calibración de los modelos SWAT

Un paso fundamental en la implementación de un modelo hidrológico es la calibración. Esta fue elaborada mediante la herramienta SWAT-CUP (Calibration and Uncertainty Programs) (Abbaspour et al., 2007). La herramienta fue desarrollada en lenguaje C++ bajo una licencia libre, que permite la ejecución de SWAT de forma independiente, es decir, funciona aparte de la interfaz gráfica (QSWAT o ArcSWAT) en las que regularmente se construyen estos modelos.

SWAT-CUP ofrece diferentes algoritmos de calibración y métodos de análisis de sensibilidad paramétrica, tales como GLUE (Generalized Likelihood Uncertainty Estimation), ParaSol (Parameter Solution), PSO (Particule Swarm Optimization), SUFI2 (Sequential Uncertainty Fitting versión 2) y MCMC (Markov Chain Monte Carlo). Para el modelo hidrológico de la cuenca del río Prado fue implementada la calibración mediante SUFI2, ya que considera varios tipos de incertidumbres representadas mediante los rangos de los parámetros (Abbaspour et al., 2007).

SUFI-2 para identificar la incertidumbre realiza dos estimaciones como lo son el factor P y el factor R. El primero es el porcentaje de datos observados dentro de la franja del 95% PPU (prediction uncertainty). El segundo es la relación entre el ancho promedio de la franja de incertidumbre 95%PPU y la desviación estándar de los datos observados. Factor P tiene un rango entre 0 – 100% mientras que el factor R tiene un rango entre 0 e infinito. Además, producto de la variación de los valores de los parámetros establecido en el proceso de calibración produce unas salidas que son expresadas por una distribución de probabilidad del 95% de certeza (95PPU) calculada por los niveles 2.5% y 97.5% de la distribución acumulada de una variable obtenida por el muestreo hipercubo latino (LHS siglas en inglés).

El procedimiento de calibración fue similar para los cuatro modelos (SWAT Pin-situ diario, SWAT Pin-situ mensual, SWAT Pdistri diario y SWAT Pdistri mensual) implementados en esta herramienta. Para ello es necesario primero un análisis de sensibilidad considerando que la calibración va a ser multi-sitio. Es decir, que un mismo parámetro se replica por cada sitio (cuenca/subcuenca) de calibración definido y este parámetro a su vez va a tener un rango diferente cuando finalice la calibración.

Con el fin de hacer una primera selección de parámetros para analizar su sensibilidad se revisaron los parámetros regularmente utilizados en procesos de calibración a través de una revisión bibliográfica (Abbaspour et al., 2017; Bai et al., 2017; Habte et al., 2013; Khalid et al., 2016; Rostamian et al., 2008; Yang et al., 2008). De la revisión se seleccionaron 16 parámetros comunes que fueron los mostrados en la siguiente lista.

r__CN2.mgt	r__SURLAG.bsn	v__ALPHA_BF.gw	v__ALPHA_BNK.rte
v__SHALLST.gw	v__ESCO.hru	v__GW_DELAY.gw	r__SOL_AWC(1).sol
v__DEEPST.gw	v__EPCO.hru	v__GW_REVAP.gw	r__SOL_K(1).sol
v__GWQMN.gw	r__SOL_AWC(1).sol	v__CH_K2.rte	v__RCHRG_DP.gw

.mgt relación con la administración del recurso hídrico y las coberturas .

.gw relación con el acuífero somero y profundo

.rte relación con los canales (ríos o quebradas) flujo del agua y los sedimentos

.sol relación con las características físicas del suelo

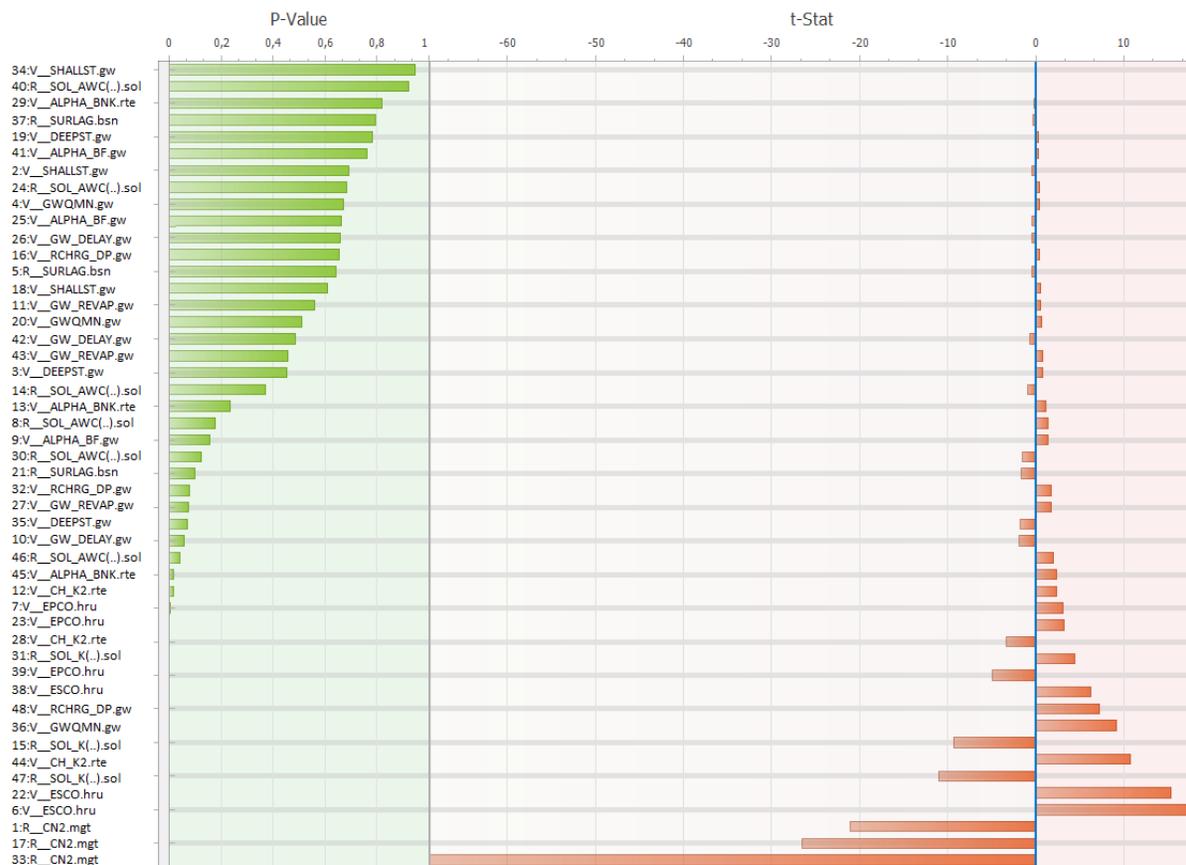
.bsn relación con procesos físicos a nivel de cuenca

.hru relación con los parámetros y procesos a nivel de HRU

Ahora bien, por cada sitio (Cunday, San Pablo y Prado) se replicaron los 16 parámetros elegidos para obtener un total de 48 parámetros sujetos al análisis de sensibilidad. Para

evaluar la sensibilidad de cada parámetro SUFI-2 utiliza P-value y t-Test al identificar la variación media de la función objetivo cuando se modifica cada parámetro mientras se cambian todos los restantes. Por lo tanto, entre más grande sea el valor del t-test y menor sea el de P-value más sensible es el parámetro como se muestra en la Figura 5-7.

Figura 5-7. Resultado análisis de sensibilidad de 48 parámetros en SWAT-CUP



Fuente: tomado de SWAT-CUP

Dadas las longitudes de las series de caudales de las tres estaciones se establecieron un periodo de calibración para las subcuencas Cunday y San Pablo va desde 1981 a 2002 y el restante tiempo hasta 2012 fue de validación. En el caso de la cuenca Prado la estación Boquerón fue definido como calibración desde 1981 a 1996 y el restante tiempo hasta 2002 sería de validación.

Los caracteres “r__” y “v__” no hacen parte del nombre del parámetro, pero señalan la manera en la cual el parámetro es modificado en cada simulación dentro del rango introducido. Cuando usa “r” significa que el valor que ya tiene el parámetro se modifica de forma relativa en el porcentaje del rango. Por ejemplo, si el rango está entre -0.2 y 2 el valor reemplazado

corresponderá a valor existente más o menos un 20%. A diferencia de los parámetros con la letra “v” en los cuales el valor del rango es el valor absoluto que toma el parámetro. Si el rango está entre -0.2 y 2 quiere decir que el parámetro en todas las cuencas tomará el valor exacto entre de -0.2 como mínimo o de 0.2 como máximo.

Con el ánimo de hacer una calibración más eficiente mediante la focalización de los parámetros, de los 48 parámetros mostrados en la Figura 5-7 se seleccionaron los 17 parámetros más sensibles para efectuar la calibración. Entre ellos están CN II Numero Curva método SCS en condición de humedad II, EPCO Factor de compensación de la absorción de agua de la vegetación, ESCO Factor de compensación de la demanda de ET en estratos superiores, CH_K2 conductividad hidráulica efectiva en el canal principal, SOL_K(1) conductividad hidráulica saturada, RCHRG_DP fracción de percolación al acuífero profundo y GWQMN valor umbral de aporte de caudal base.

En la Tabla 5-2. se muestran los resultados de calibración con los parámetros y los rangos de valores en el caso del modelo SWAT Pin-situ a escala mensual.

Tabla 5-2. Parámetros definitivos durante la calibración en SWAT-CUP

Parámetro	Unidades	Cuenca	Rango	
			mín	máx
CN II	--	Cunday	-0.468277	-0.101579
CN II	--	San Pablo	-0.490182	-0.106334
CN II	--	Prado	-0.663709	-0.020791
EPCO	--	Cunday	0.737655	1.397605
EPCO	--	San Pablo	0.40178	0.87313
EPCO	--	Prado	-0.214368	0.595718
ESCO	--	Cunday	-0.241141	0.264395
ESCO	--	San Pablo	0.209112	0.628196
ESCO	--	Prado	-0.076645	0.641645
CH_K2	mm/hr	Cunday	23.769634	69.435593
CH_K2	mm/hr	San Pablo	36.001583	106.159973
CH_K2	mm/hr	Prado	43.856129	121.768875
SOL_K(1)	--	Cunday	-0.034294	0.568656
SOL_K(1)	--	San Pablo	-0.773185	0.646657
SOL_K(1)	--	Prado	-1.46265	0.04665
RCHRG_DP	--	Prado	0.453359	1.361641
GWQMN	mm	Prado	1479.247803	4445.751953

Fuente: Elaboración Propia

La función objetivo utilizada durante la calibración fue NSE (Nash-Sutcliffe Efficiency) regularmente llamada coeficiente de Nash. La ecuación de NSE es descrita en el apartado 5.2.1.1 de la página 43. Los resultados de ambos procesos según la función objetivo se muestran en la Tabla 5-3.

Tabla 5-3. Resultados NSE para calibración y validación en SWAT-CUP.

Subcuenca	Pin-situ diario		Pdistri diario		Pin-situ mensual		Pdistri mensual	
	Cal	Val	Cal	Val	Cal	Val	Cal	Val
Cunday	-6.34	-6.81	-0.63	-0.64	0.15	0.16	0.56	0.57
San Pablo	-5.85	-4.02	-0.66	-0.51	-0.09	-0.08	0.73	0.78
Prado	-6.77	-7.5	-2.82	-3.1	0.20	0.21	-0.92	-1.01

Fuente: Elaboración propia

5.1.1.2. Modelo Deep Learning: a través de la herramienta Keras

El enfoque de los otros dos miembros locales es el de modelos basados en datos tipo *RNA – DL* pero utilizando la herramienta Keras. Esta herramienta es una librería nivel-modelo usada por grandes compañías como Google, Netflix, Uber, CERN, Yelp, Square (Chollet, 2015) que provee bloques constructivos para desarrollar modelos *Deep Learning* DL. La librería es distribuida bajo licencia de MIT. Para desarrollar modelos DL, Keras preferiblemente enfrenta los problemas de una manera modular utilizando motores (*backend*⁸) que pueden ser conectados a Keras. Los *backend* más reconocidos son *TensorFlow* (Abadi et al., 2015), *Theano* (Al-Rfou et al., 2016) y *Microsoft Cognitive Toolkit* (CNTK) (Agarwal et al., 2014). Uno puede ser más rápido que el otro para ciertos procesamientos, lo que implica la oportunidad para los desarrolladores de utilizarlos indistintamente entre ellos con la misma programación, con el mismo código.

Tensorflow y Keras mediante el lenguaje Python fueron utilizados para crear una red neuronal tipo Gran Memoria de Corto Plazo (en inglés LSTM - *Long short-term memory*-) para predecir

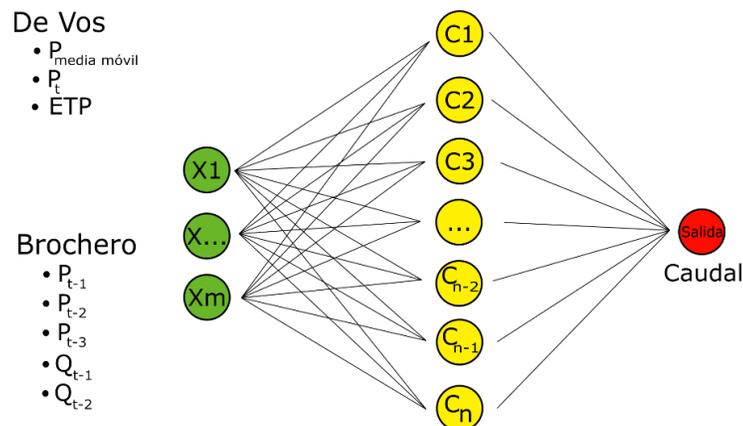
⁸ Backend: término de la ingeniería de software que conceptualmente separa la parte visual de información llamada *frontend* y la parte oculta de acceso y manipulación de la información a nivel de máquina llamada *Backend*. En el caso más preciso de compiladores (programación) se refiere a la parte interna de un programa que se encarga de optimizar un código para hacer más rápida su compilación.

flujos en alcantarillado (Zhang et al., 2017); también, para mejorar la operación de alcantarillado combinado mediante la red neuronal LSTM y GRU (*Gated Recurrent Unit*) (Zhang et al., 2018); adicionalmente, analizar el ENSO y mejorar la predicción de caudales mediante una red neuronal LSTM (Huang et al., 2019); mejorar la predicción de caudales a través de la comparación de 4 redes neuronales, una de ellas LSTM (Tian et al., 2018); y para emular un modelo de Circulación Global mediante una red neuronal convolucional (en inglés CNN - *Convolutional neural network*-) (Scher, 2018).

Keras dispone de dos tipos de modelos: modelos secuenciales y modelos de clases con una API funcional. El tipo de modelo usado en este trabajo de grado fue el secuencial ya que este modelo permite operarse sin tener un elevado conocimiento de programación, además, tiene un uso extendido.

La construcción del modelo Keras *DL* para estimar los caudales del caso de estudio requirió la definición de la arquitectura de la red neuronal, la cual fue una Red Neuronal Preadalimentada (en inglés FFN –*Feed-Forward Network*–) porque se conocía la cantidad y dimensiones (variables de entradas) de datos del problema, por su uso generalizado y por su simpleza. Las FFN son relativamente fáciles de operar y consisten mínimo de dos capas, una de entrada y una de salida, pero en este caso la red utiliza tres capas de neuronas como se muestra en la Figura 5-8. En FFN las neuronas no tienen comunicación entre ellas en una misma capa. La primera capa de neuronas (círculos verdes) reciben las variables de entrada, luego pasan por una capa oculta (círculos amarillos) de aprendizaje, de estimación de pesos y de predicción, finalmente, en la tercera capa de salida (círculo rojo).

Figura 5-8. Arquitectura Red Neuronal Artificial tipo creada para el modelo DL-Keras con entradas De Vos y Brochero



Fuente: Modificado Abdullahi & Elkiran (2017)

La construcción del modelo Keras DL llevó varios pasos que siguen la forma básica de operación de una red neuronal como se muestra en la Figura 5-9, en la cual se tienen series de tiempo de las variables hidroclimatológicas, es decir, las entradas del modelo para un periodo de calibración y entrenamiento conformado con el primer 70% de los datos. El restante 30% se deja para su validación.

Figura 5-9. Estructura de una red neural artificial.



Fuente: modificado de Chollet (2015)

Luego, se transforman estos datos mediante una función de aprendizaje, generando una nueva serie de predicciones o estimaciones que se comparan con los datos observados (objetivos verdaderos), mediante una función de pérdida o función objetivo, en caso de que los valores de puntuación de pérdida no cumplan con los trazados, se utiliza un optimizador para actualizar los pesos y transformar una vez más los datos y repetir este proceso hasta que el entrenamiento o aprendizaje sea lo mejor posible para la estructura de la red neuronal y de la calidad de información de entrada. La visualización del proceso de aprendizaje se muestra en la Figura 5-10.

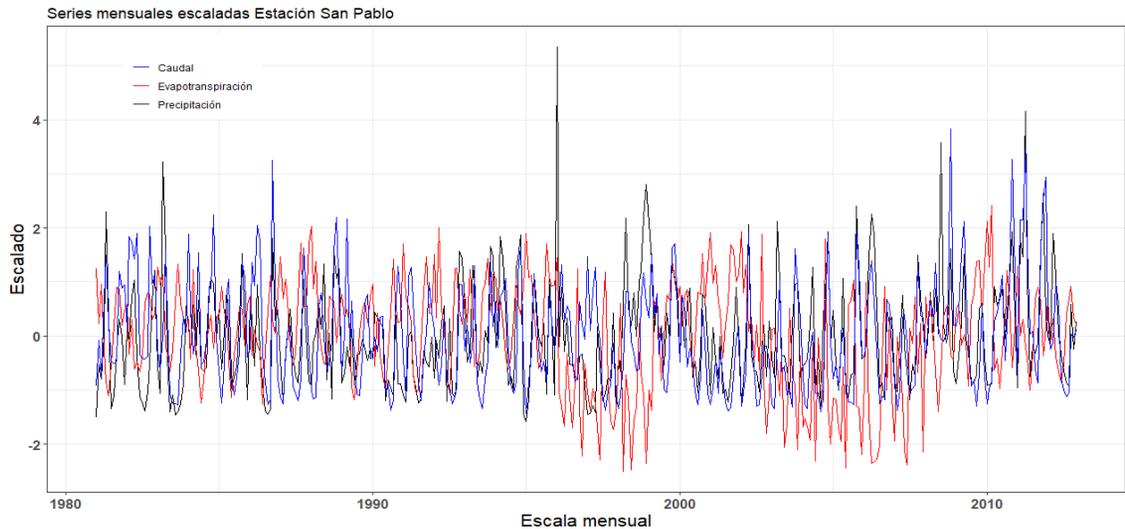
Figura 5-10. Ejemplo del proceso de entrenamiento de Keras en R.



Fuente: Elaboración propia

Un paso previo, realizado antes de ingresar los datos al proceso de aprendizaje, y que no es estrictamente necesario en los procesos de aprendizaje autónomo, fue la estandarización de los datos para ayudar el proceso de aprendizaje, ya que la magnitud de los datos de entrada no es son la mismos. La estandarización utilizó el valor promedio y desviación estándar. Un ejemplo de las series mensuales estandarizadas para una subcuenca del caso de estudio es mostrado en la Figura 5-11.

Figura 5-11. Ejemplo serie de caudales, precipitación y evapotranspiración escalada



Fuente: Elaboración propia

Los resultados del entrenamiento y aprendizaje (calibración) y validación de los datos se muestran en la Tabla 5-4. Cabe recordar que el periodo de calibración para las subcuencas

Cunday y San Pablo va desde 1981 a 2002 y el restante tiempo hasta 2012 fue de validación. En el caso de la cuenca Prado la estación Boquerón fue definido como calibración desde 1981 a 1996 y el restante tiempo hasta 2002 sería de validación

Tabla 5-4. Resultados proceso de calibración y validación para DL-Keras

Subcuenca	KerasDeVos diario		KerasBrochero Diario		KerasDeVos Mensual		KerasBrochero mensual	
	Cal	Val	Cal	Val	Cal	Val	Cal	Val
Cunday	0.16	0.10	0.39	0.37	0.45	0.32	0.35	0.28
San Pablo	0.14	0.23	0.35	0.45	0.32	0.43	0.30	0.29
Prado	-0.25	-0.28	-0.16	-0.20	0.18	-0.87	0.49	0.47

Fuente: Elaboración propia

5.1.2. Modelos hidrológicos regionales

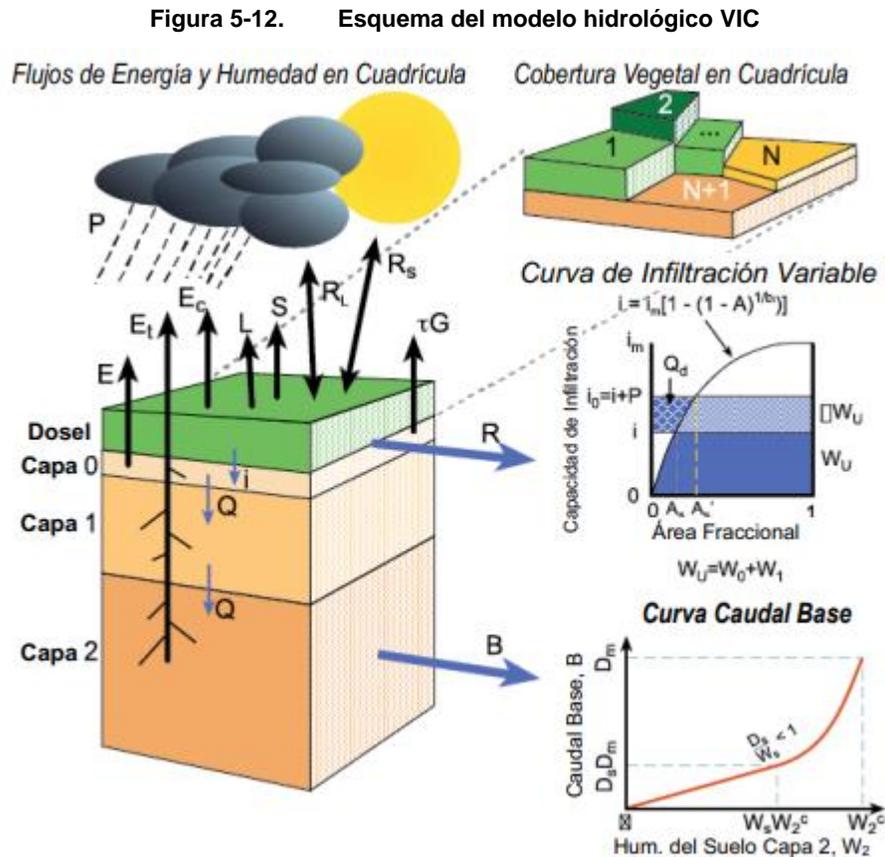
Se les denomina modelos regionales a los modelos hidrológicos desarrollados en el marco del proyecto *earth2observe* para el caso de estudio de la cuenca de los ríos Magdalena-Cauca, Colombia (CMC). En el marco de ese proyecto fueron usados los modelos VIC y MESH, entre otros. El proyecto desarrolló otros modelos que no fueron vinculados porque sus puntos de control se localizaban fuera de la cuenca Prado que no permitían contrastar con las estaciones hidrométricas Boquerón, Pte. Cunday y San Pablo.

5.1.2.1. Variable Infiltration Capacity (VIC)

VIC (capacidad de infiltración variable) es un modelo hidrológico semidistribuido de gran escala tipo superficie-terrestre en combinación con Modelos de Circulación Global (GCM) resuelve el balance hídrico y de energía a escala de tiempo diaria y subdiaria (Liang et al., 1994). VIC fue desarrollado en la Universidad de Washington y es de código abierto.

En VIC las celdas son planas y uniformes de tamaño superior a un (1) km² en las cuales las elevaciones y coberturas son tenidas en cuenta bajo distribuciones estadísticas. Una situación particular de VIC es que el agua solo ingresa mediante la parte atmosférica y el flujo diferente al de los canales no se considera. Por lo tanto, el flujo que ingresa en un canal se mantiene en él y no regresa al subsuelo.

El enrutamiento del modelo se hace mediante un módulo separado en donde cada celda opera como un nodo de la red de drenaje. En esta red se moviliza el flujo superficial y subsuperficial hacia la salida de la cuenca representando una hidrógrafa. Allí, se cuantifica el transporte mediante las ecuaciones de Saint Venant.



Fuente: modificado Liang et al.(1994)

5.1.2.2. *Modélisation Environnementale Communautaire* - MEC-Surface & Hydrology - MESH

El modelo MESH (Pietroniro et al., 2007) es la combinación de los modelos CLASS (*Canadian Land Surface Scheme*) (Verseghy, 2000) y del módulo de tránsito de WATFLOOD (Kouwen et al., 1993). Este modelo hace parte del sistema operacional de pronóstico y cambio climático y

ambiental de Canadá, que fue desarrollado por varias universidades y el Departamento de Ambiente de este país.

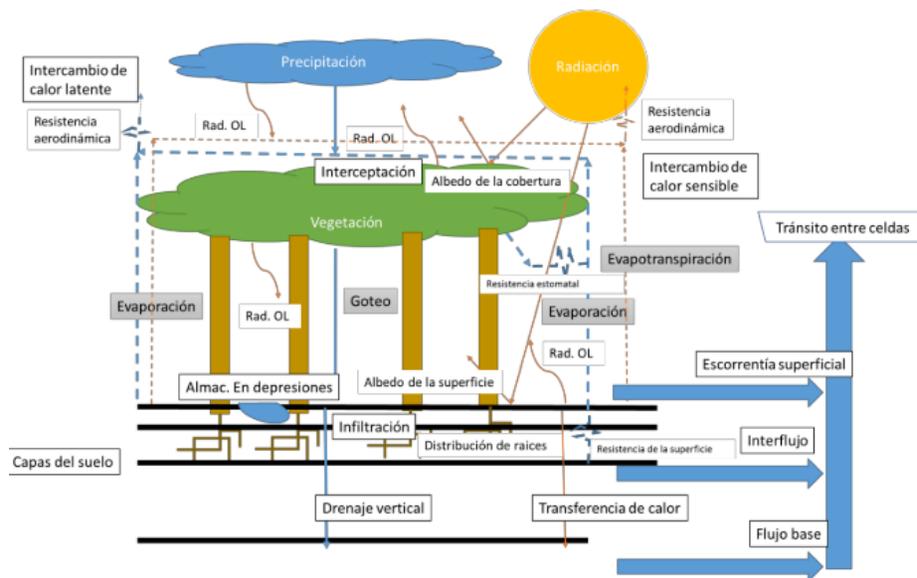
Es un modelo tipo superficie-terrestre que acopla los diferentes componentes de este tipo de modelos con un modelo hidrológico y según la necesidad pudiese ser acoplado con un modelo atmosférico que ingrese los forzamientos climáticos que requiere MESH.

Una manera de agrupar la superficie terrestre se realiza mediante los Grupos de Respuesta Unitaria (GRU) que son grupos de áreas similares en los cuales se efectúan las simulaciones o cálculos matemáticos del modelo superficie terrestre como el hidrológico.

Las entradas del modelo MESH son siete datos meteorológicos: precipitación, temperatura, radiación de onda corta, radiación de onda larga, velocidad del viento, humedad específica y presión atmosférica. También es necesaria la definición de tres capas del suelo por parte del usuario, parámetros de vegetación, del suelo y de GRU. Por otro lado, se agregan la red de drenaje, parámetros del flujo base y de la escorrentía para WATFLOOD, los puntos de control con los caudales observados.

MESH es un modelo complejo que permite simular múltiples procesos tanto de balance de energético como de balance hídrico como lo muestra la Figura 5-13.

Figura 5-13. Esquema funcionamiento modelo MESH



Fuente: tomado de (Arboleda-Obando, 2018) y modificado Versegny (2000) Kouwen et al. (1993).

5.1.3. Modelos hidrológicos globales

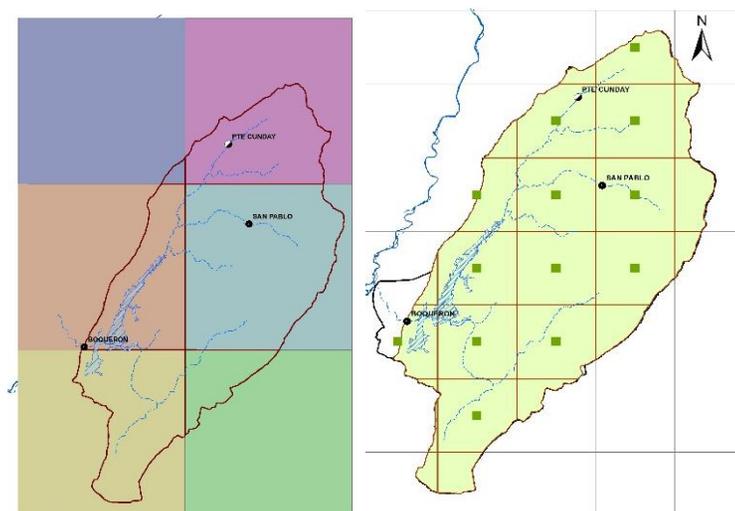
Modelo global se denomina a aquellos modelos desarrollados a escala global 0.5° y 0.25° que fueron utilizados en el proyecto *earth2observe*. Un total de once modelos globales fueron usados, de los cuales ocho son reconocidos en la literatura como Modelos Hidrológicos Globales (*HGM* siglas en inglés) y dos restantes Modelos de Tierra-Superficie (*LSM* siglas en inglés). Todos los modelos globales usados hicieron parte del *earth2observe* (Schellekens et al., 2017) con excepción de *Global Land Data Assimilation System* (GLDAS) (Rodell et al., 2004).

En mención, en el proyecto *earth2observe* Colombia se investigó cómo aportaba el uso de datos de diferentes forzamientos y de un ensamble hidrológico en la macrocuenca Magdalena-Cauca, a la generación de información más confiable para el proceso de toma de decisiones. Lo anteriormente mencionado era realizado mientras se investigaba la disponibilidad del recurso hídrico y la variabilidad hidrológica (Rodríguez et al., 2016; Schellekens et al., 2017).

El modelo GLDAS provenía a escala 0.25° y su malla se observa en la parte izquierda de la Figura 5-14, con un tamaño promedio de 27.7 km. La información provenía en formato netCDF y se utilizó el paquete *ncdf4* (Pierce, 2017) de la herramienta R Studio para su extracción y manipulación de los datos como listas, matrices o arreglos.

Los demás modelos globales que fueron desarrollados a escalas 0.5° y 0.25° se obtuvieron escalados a 10 x 10 km como parte de los resultados del proyecto *earth2observe*. La malla de esta escala se ilustra en la parte derecha de la Figura 5-14.

Figura 5-14. Malla modelo GLDAS 0.25° (Izq.) y malla modelos regionales y globales provenientes del earth2observe (Der.)



Fuente: Elaboración propia

Los nombres que a lo largo del presente trabajo llevan los modelos corresponde al centro de investigación o agencia que los desarrollaron. Adicionalmente, la lista contiene ocho modelos globales a 0.5°, de los cuales JRC, KASSEL y ECMWF se incluyeron también a escala 0.25°. En cada ítem de la siguiente lista se encuentra en **negrita** el nombre del modelo hidrológico como el centro de investigación lo llamó.

- CNRS: Centre National de la Recherche Scientifique. Modelo **ORCHIDEE** (Krinner et al., 2005). Es el resultado del acoplamiento del modelo de tierra-superficie SECHIBA y el modelo de vegetación carbono STOMATE.
- CSIRO: Commonwealth Scientific and Industrial Research Organisation. Modelo **W3RA** (Van Dijk, 2010) (World Water Resources Assessment) es un modelo híbrido entre modelo distribuido tipo tierra-superficie y un modelo agregado de cuenca aplicado a cada celda de la distribución espacial.
- KASSSEL: Universität Kassel (UNI KASSEL). Modelo **WaterGAP3** (Water-Global Assessment and Prognosis-3) (Flörke et al., 2013) (Döll et al., 2009) es un modelo lluvia-escorrentía distribuido que incluye módulo de calidad de agua.
- JRC: Joint Research Centre. Institute for Environment and Sustainability. Modelo **LISFLOOD** (Van Der Knijff et al., 2008). Modelo Lluvia-escorrentía espacialmente

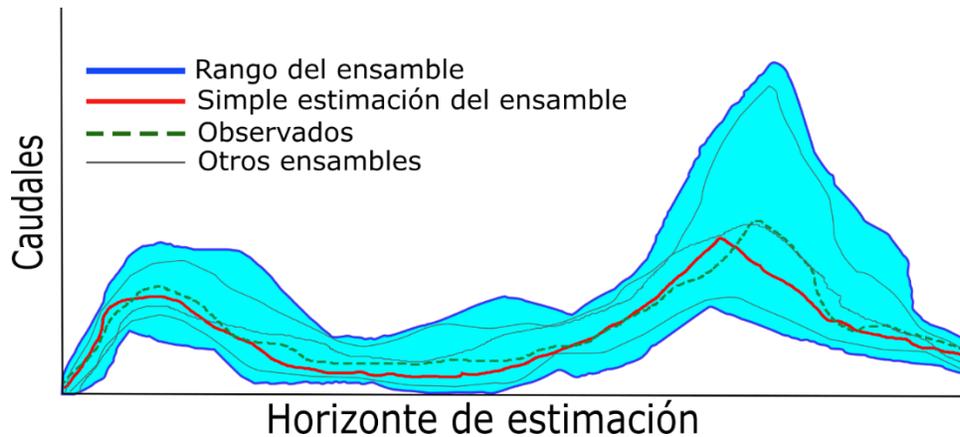
distribuido y de enrutamiento de canales con énfasis en el ciclo hidrológico para cuencas grandes.

- ECMWF: European Centre for Medium-Range Weather Forecasts (ECMWF). Modelo **HTESSEL-CaMa** (Balsamo et al., 2009). Modelo de tierra-superficie que genera la escorrentía a partir del esquema basado en cuenca a gran escala CaMa-Flood.
- UU: Universiteit Utrecht. Modelo **PCR-GLOBWB** (Sutanudjaja et al., 2018). Modelo Hidrológico Global de tanque espacialmente distribuido. El enrutamiento se hace mediante el transporte de volúmenes según el enfoque del tiempo de transporte eficiente sobre la red de drenaje.
- METEO: Météo-France Servicio Francés de meteorología. Modelo SURFEX-TRIP (Decharme et al., 2010). Tipo tierra-superficie que utiliza el modelo ISBA de múltiples capas para simular el balance hídrico y energía en suelo-nieve-vegetación. El enrutamiento se efectúa a escala global mediante modelo Trip.
- GLDAS: Global Land Data Assimilation System (Rodell et al., 2004). Es modelo que integra observaciones en tierra y satelitales para producir campos de humedad del suelo, temperatura, etc; además de flujos como evapotranspiración y escorrentía. Periodo de simulación disponible 1948 – 2014. La escala espacial de los campos de escorrentía es de 0.25° x 0.25°.

5.2. CONSTRUCCIÓN DEL ENSAMBLE HIDROLÓGICO

En general, un ensamble es un conjunto de varios miembros (modelos) en el cual cada miembro representa un posible estado del sistema o modelo evaluado. Mediante la Figura 5-15 se muestra un esquema típico de los resultados de un ensamble hidrológico donde se encuentra: la franja de incertidumbre del ensamble, la estimación determinística del mejor ensamble, los miembros que crean el ensamble y/o sus combinaciones y la serie de observados para contrastar gráficamente el desempeño del ensamble. El horizonte de estimación del caso de estudio es desde 1981-2011 porque ese es el periodo de ejecución del modelo MESH y para unificar el periodo se desestimó un año de todos los otros miembros del ensamble que existían hasta el 2012.

Figura 5-15. Esquema general de un ensamble hidrológico



Fuente: modificado Dietrich (2008)

5.2.1. Evaluación de desempeño de ensambles y modelos hidrológicos

Con la idea de discutir posteriormente los resultados de las simulaciones, tanto de los modelos, como del ensamble se mencionan las siguientes métricas estadísticas y probabilísticas. El uso de las métricas permite ofrecer indicadores de la habilidad del modelo para reproducir el comportamiento de los caudales en una cuenca, suministrar una media para evaluar mejoramientos de modelos o métodos y proveer un mecanismo de comparación de resultados en diferentes estudios e inclusive para la selección de un mejor modelo dentro de un grupo de opciones (Dawson et al., 2010).

5.2.1.1. NSE

Nash-Sutcliffe Efficiency (NSE) se utiliza para estimar la capacidad predictiva de un modelo hidrológico. NSE es sensible a los valores extremos castigando el desempeño de la simulación por su presencia. El rango de la métrica es de -infinito a 1. En este caso, el valor de 1 sería un ajuste perfecto de los caudales simulados con los caudales observados. En caso de ser negativo, la estimación del modelo no es mejor que el promedio de los observados (Nash and Sutcliffe, 1970).

$$NSE = 1 - \frac{\sum_{i=1}^n (q_{obs} - q_{sim})^2}{\sum_{i=1}^n (q_{obs} - \bar{q})^2} \quad \text{Ecuación 5-2}$$

donde,
n: número de pasos de tiempo (datos)

q_{obs} : serie de caudales observados

q_{sim} : serie de caudales simulados

\bar{q} : promedio de los caudales

5.2.1.2. KGE

Kling-Gupta Efficiency (KGE) provee un diagnóstico descomposición del NSE. El rango de KGE está entre -Infinito y 1. Entre más cerca de 1 el valor, mejor es el modelo. Gupta (2009) sugiere esta métrica como alternativa de evaluación del desempeño de un modelo, ya que con NSE se reportaban subestimación de valores cuando se quería maximizar la variabilidad. Además, al escalar el sesgo con la desviación estándar de los datos observados, como hace NSE, se presenta dificultad al comparar cuencas diferentes (Gupta et al., 2009).

$$KGE = 1 - ED$$

Ecuación 5-3

$$ED = \sqrt{[S_r \cdot (r - 1)]^2 + [S_\alpha \cdot (\alpha - 1)]^2 + [S_\beta \cdot (\beta - 1)]^2}$$

Ecuación 5-4

$$\beta = \mu_s / \mu_o$$

Ecuación 5-5

donde,

ED : distancia Euclidiana al punto ideal

β : tasa entre promedio simulados y promedio de los observados (sesgo)

S_r, S_α, S_β : factores de escala

r : valor máximo de KGE si los otros dos componentes logran un valor cercano a 1

5.2.1.3. CRPS

Continuous Rank Probabilistic Score (CRPS) es el valor del rango de probabilidad continuo. CRPS contribuye a evaluar la confiabilidad de un ensamble. Es una medida de la integral al cuadrado de la diferencia entre la función de distribución acumulada de la predicción y la función de distribución de las observaciones. El valor perfecto sería 0 y utiliza las mismas unidades de la variable observada (Gneiting and Raftery, 2007).

$$CRPS(F, x) = \int_{-\infty}^{\infty} (F(y) - \mathbb{1}(y - x))^2 dy \quad \text{Ecuación 5-6}$$

X: variable aleatoria

F: función de distribución acumulada (CDF) de X asociada a una predicción o pronóstico probabilístico, como $F(y) = P [X \leq y]$

$\mathbb{1}$ es una función escalonada de Heaviside

Desde el punto de vista numérico se requiere abrir la integral con otros límites para simplificar la función escalonada de Heaviside quedando como en la ecuación 4-7.

$$CRPS(F, x) = \int_{-\infty}^x F(y)^2 dy + \int_x^{\infty} (F(y) - \mathbb{1})^2 dy \quad \text{Ecuación 5-7}$$

El valor resultante se expresa en las mismas unidades de la variable observada, es decir que en este caso será en m³/s.

5.2.2. Transformación de Johnson

La transformación de Johnson (Chou et al., 1998) se utiliza para ajustar un grupo de datos de cualquier distribución a una normal. Los caudales son una variable aleatoria que no siempre se rige a las características de una distribución normal y tienden a ser sesgadas (Raftery et al., 2005). Para enfrentar ese tipo de casos se han planteado transformaciones a los datos para ajustarlos permitiendo cumplir con el requisito de ajuste a la distribución normal por parte del Método del Promedio Bayesiano - BMA.

Johnson definió tres tipos de distribuciones posibles para el grupo de datos:

Sb: X acotada

Sl: X acotada por debajo o lognormal

Su: X no-acotada

$$\text{Sb} \quad Z = \gamma + \eta \ln \left(\frac{X - \epsilon}{\lambda + \epsilon - X} \right) \quad \eta, \lambda > 0, -\infty < \gamma < \infty, -\infty < \epsilon < \infty \quad \text{Ecuación 5-8}$$

$$\text{Sl} \quad Z = \gamma + \eta \ln (X - \epsilon) \quad \eta > 0, -\infty < \gamma < \infty, -\infty < \epsilon < \infty \quad \text{Ecuación 5-9}$$

$$\text{Su} \quad Z = \gamma + \eta \sinh^{-1} \left(\frac{X - \epsilon}{\lambda + \epsilon - X} \right) \quad \eta, \lambda > 0, -\infty < \gamma < \infty, -\infty < \epsilon < \infty \quad \text{Ecuación 5-10}$$

Según la familia a la cual pertenezca la serie de información se realiza la transformación.

5.2.3. Análisis de ensambles hidrológicos desde una perspectiva Bayesiana

Método Bayesiano (siglas en inglés BMA, *Bayesian Model Averaging*) es un método probabilístico propuesto para calibrar ensambles con fines de pronóstico y/o predicción. BMA busca combinar predicciones o estimaciones de diferentes modelos para generar un nuevo modelo que se espera sea mejor que los demás modelos. Para ello se requiere la estimación de pesos y varianzas de cada miembro (modelo) del ensamble basado en la probabilidad condicional de cada modelo y de su unicidad.

El BMA es un método que permite no repetir la regular manera de seleccionar un mejor modelo dentro de una baraja de opciones, la cual, mediante regresiones (e.g. regresión lineal) designa un único modelo como mejor opción, sin considerar que otros modelos pueden ofrecer interesantes consideraciones a la predicción, así se puede subestimar la incertidumbre inherente de los modelos.

La función de densidad de probabilidad (PDF) del ensamble es un promedio ponderado de las funciones de densidad de probabilidad de cada modelo aplicadas sobre el periodo de calibración. Broderick (2016) recomienda el uso de BMA para la estimación de pesos en modelos climatológicos.

Si se considera una cantidad y a ser estimada basada en el entrenamiento y^T utilizando K modelos estadísticos M_1, \dots, M_k . la ley de probabilidad total menciona que las PDF de la predicción $p(y)$, están regidas por la Ecuación 5-11.

$$p(y) = \sum_{k=1}^K p(y|M_k) p(M_k|y^T) \quad \text{Ecuación 5-11}$$

donde,

$p(y|M_k)$ PDF de la predicción basado en el modelo K únicamente.

$p(M_k|y^T)$ probabilidad posterior al modelo K luego de corregida para el periodo de entrenamiento mostrando cuan bueno es el modelo K .

Las probabilidades siguientes de los otros modelos sumadas deben ser 1, $\sum_{k=1}^K p(M_k|y^T) = 1$, de esta manera podrán ser vistas como pesos. Los pesos son mayores cuando el modelo tiene mejor comportamiento predictivo.

Para el caso de modelos dinámicos, la probabilidad está dada por la Ecuación 5-12.

$$p(y|f_1, \dots, f_K) = \sum_{k=1}^K w_K g_K(y|f_k) \quad \text{Ecuación 5-12}$$

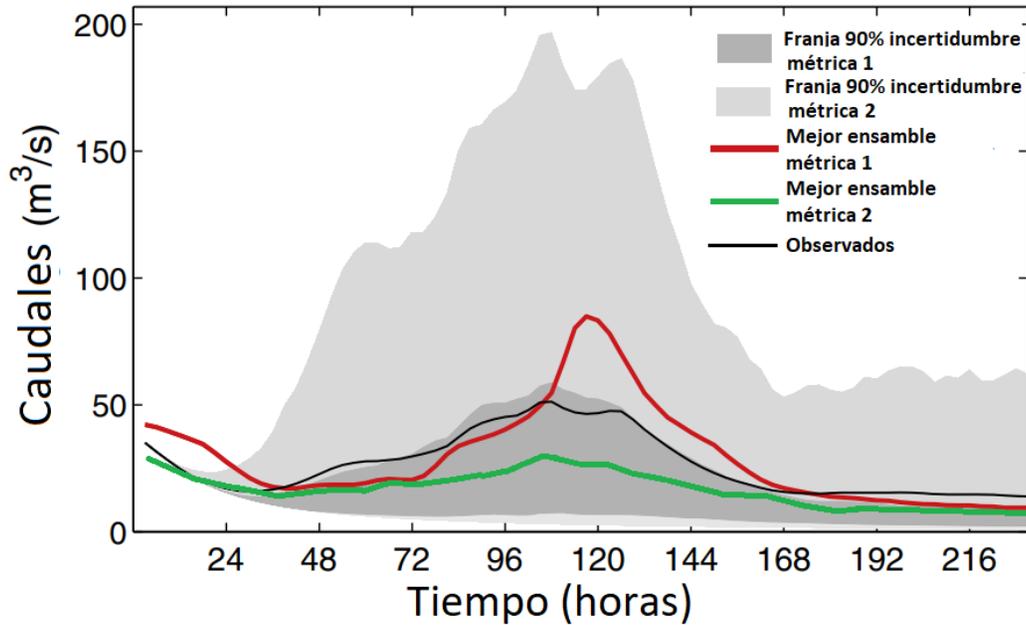
Considerando la hipótesis de normalidad, la PDF del modelo estimado $g_K(y|f_k)$ es aproximadamente $g_K(y|f_k) \sim N(f_k, \sigma_k)$ donde σ_k es la varianza del ensamble.

5.2.4. Evaluación de la Incertidumbre de los ensambles hidrológicos

Una vez se define el nuevo mejor ensamble (NME) para cada métrica, dentro de un ejercicio de generación de un ensamble hidrológico se busca evaluar la incertidumbre del mismo, mediante la obtención de una franja o intervalo de incertidumbre.

Utilizando el método de Monte-Carlo y BMA se genera un intervalo del 90% de incertidumbre producto del rango de cuantiles 5% y 95% de los estimados para cada paso de tiempo (Arboleda-Obando et al., 2018; Dong et al., 2013). En la Figura 5-16 se muestra un esquema de franja de incertidumbre para dos mejores ensambles según una métrica, pero la franja puede ser estimada para cualquier ensamble sin la denominación de mejor, depende del tipo de ensamble que se esté buscando.

Figura 5-16. Ejemplo intervalo de incertidumbre del 90% de un mejor ensemble ME



Fuente: Modificado de Bennett et al, (2014)

En más detalle, Dong, (2013) indica una serie de tres pasos principales para lograr la estimación de la incertidumbre.

- Primero se genera un valor entero k , desde $[1, 2, \dots, K]$ correspondiente al número de modelos, incluyendo el peso.
- Segundo, se debe recalcular el valor del valor simulado en el ensemble (caudal) desde la PDF $g(Q_t|f_k^t, \sigma_k^2)$ donde la probabilidad de g corresponde a una distribución normal con valor promedio f_k^t y varianza σ_k^2 .
- Repetir los dos pasos anteriores por M cantidad de pasos. Así, el ensemble se vuelve a un tamaño de M valores por cada paso de tiempo. Así, se logra una franja como la mostrada en la Figura 5-16.

El desempeño del intervalo de predicción se evalúa mediante tres criterios o índices como señala Dong, (2013). Ellos son CR (Containing Ratio), ADA (Average Deviation Amplitude) y ABW (Average Band-Witdh).

CR: relación de contenidos es una medida del ajuste del intervalo de confianza y se define como el porcentaje de datos observados que se ubican dentro del rango o límite de las predicciones.

ADA: Promedio de la ampliación de la desviación

$$ADA = \frac{1}{T} \sum_{t=1}^T \left| \frac{1}{2} (q_u^t - q_l^t) - Q_{obs}^t \right| \quad \text{Ecuación 5-13}$$

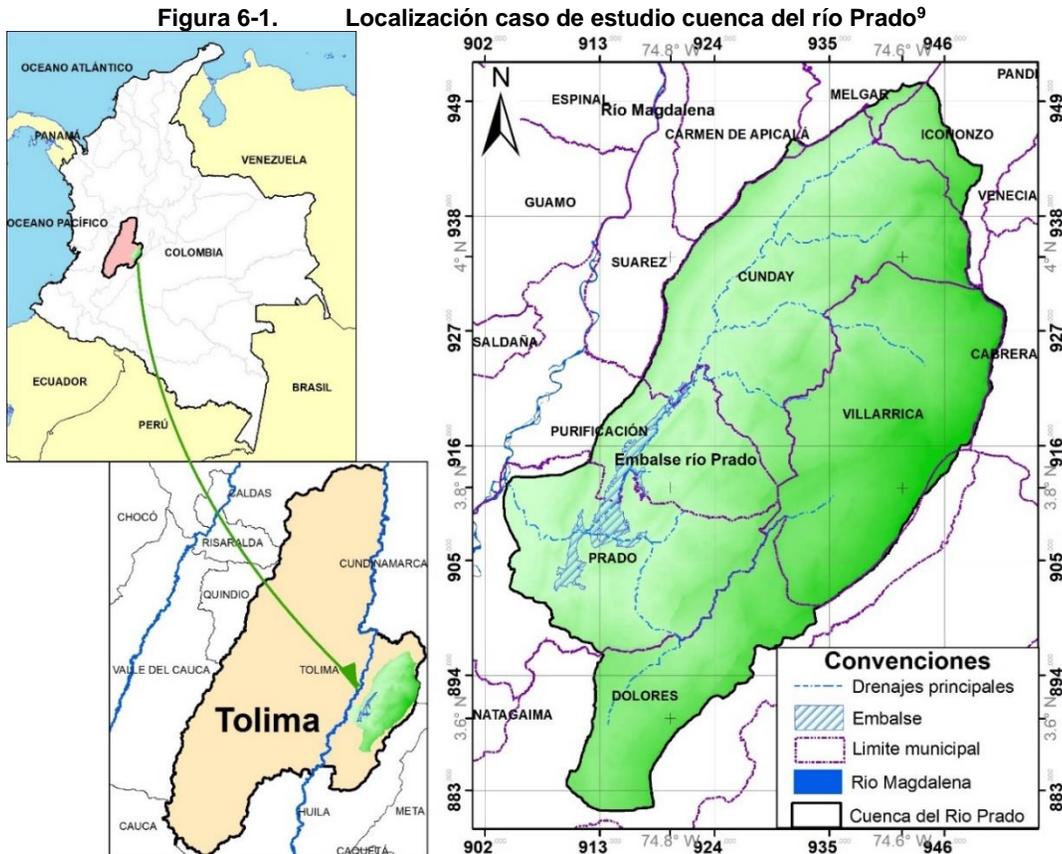
donde q_u^t y q_l^t son denominados como límite bajo y superior de la predicción en cada tiempo t y Q_{obs}^t caudal observado tiempo t.

ABW: Promedio del ancho de la franja

$$ABW = \frac{1}{T} \sum_{t=1}^T (q_u^t - q_l^t) \quad \text{Ecuación 5-14}$$

6. CASO DE ESTUDIO

La descripción de la cuenca de estudio, aparte de reconocer el sitio de ejecución del trabajo de grado, busca permitirle a lectores e interesados la aplicación de ensambles hidrológicos en otras cuencas de características morfométricas y de oferta de servicios ecosistémicos similares.



Fuente: Elaboración propia

La cuenca del río Prado se localiza en el costado oriental del Departamento del Tolima, en la margen derecha del río Magdalena. La cuenca toma el nombre del río principal que recibe de

⁹ Sistema de coordenadas: La figura de localización muestra coordenadas geográficas WGS84 y en Magna Sirgas Colombia Bogotá origen central código WKID 3116. Este último sistema es el utilizado en todas las figuras con mapas del documento.

afluentes que en su mayoría fluyen en sentido norte sur y oriente occidente hasta entregar sus aguas al río Magdalena. La cuenca completa tiene un área de 1.616 km² (ver Figura 6-1).

Administrativamente, la cuenca se ubica sobre 7 municipios del Departamento del Tolima: Cunday, Villarrica, Prado, Dolores, Purificación, Icononzo y Melgar con una participación de 500.4 km² (31.0 %), 428.4 km² (26.5 %), 296.3 km² (18.3 %), 229.6 km² (14.2%), 157.6 km² (9.8%), 49 km² (3.0 %), 10 km² (0.6%), respectivamente. Dada la participación administrativa, en la cuenca hay aproximadamente 50.000 personas que demandan 170 lt/hab/día en las cabeceras municipales y 120 lt/hab/día en la zonas rurales (Cortolima, 2005).

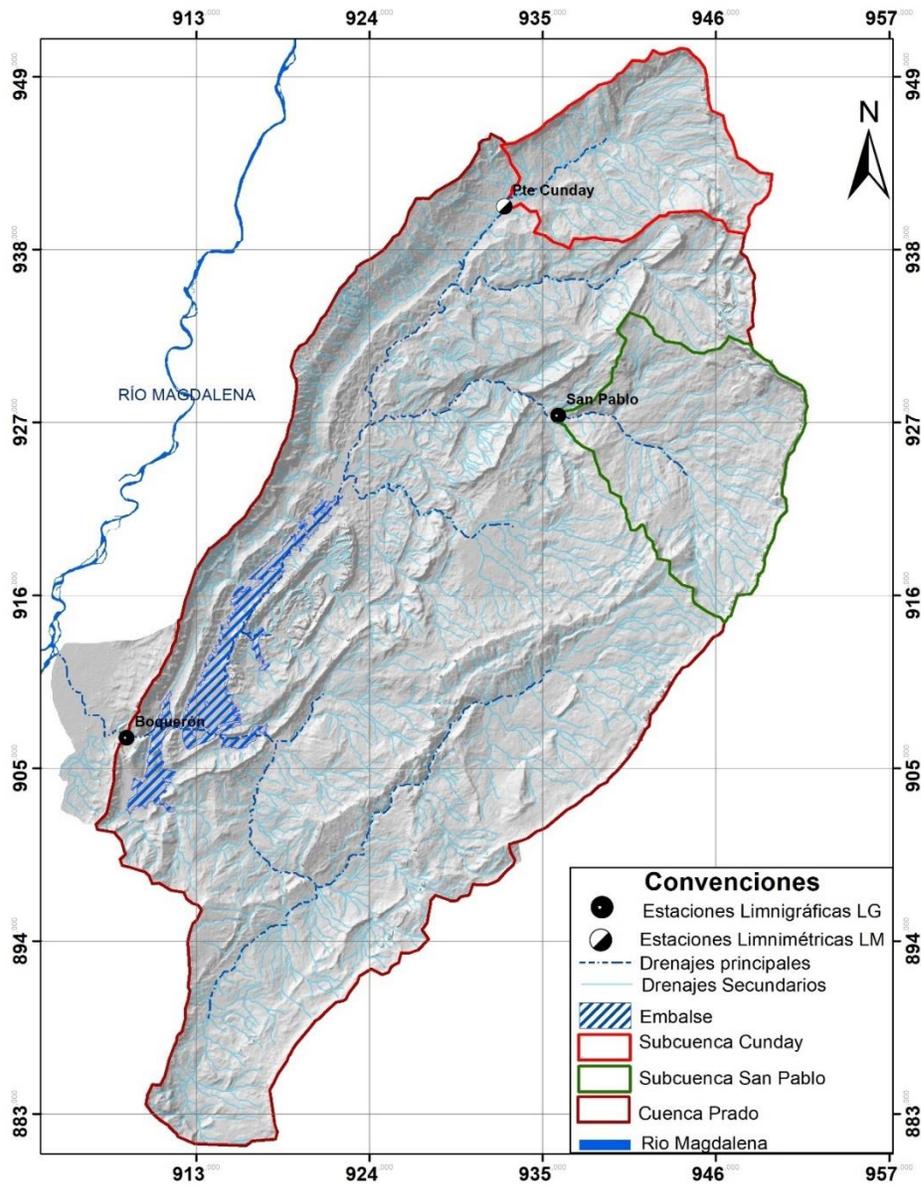
La cuenca del río Prado es elegida como caso de estudio porque es una cuenca que presta variados servicios ecosistémicos, existe presión sobre el recurso hídrico, hay mediciones (estaciones hidroclimatológicas) y se quiso conocer el comportamiento de los modelos locales frente a la carencia de información de operación de la hidroeléctrica. Adicionalmente, da continuidad con la investigación abordada por el ingeniero David Andrés Zamora Ávila, en su proyecto de tesis doctoral aplicada en la misma cuenca, específicamente en su tercer objetivo que señala: *“Evaluar la incertidumbre con relación a la toma de decisiones frente a los servicios ecosistémicos y la influencia de las dinámicas sociocológicas en la capacidad resiliente de los ecosistemas bajo umbrales a partir del análisis de escenarios de mediano y largo plazo”*.

6.1. MORFOMETRÍA DE LAS SUBCUENCAS

Antes de mencionar los parámetros morfométricos de las cuencas se aclara su definición, la cual se debe a la ubicación de las estaciones hidrométricas Puente Cunday, San Pablo y Boquerón. La estación limnimétrica Puente Cunday ubicada sobre el río del mismo nombre generó la subcuenca Cunday, la estación limnigráfica San Pablo sobre el río Cuindé generó la cuenca San Pablo y la estación limnigráfica Boquerón aguas abajo del embalse definió la cuenca del río Prado (ver Figura 6-2). Los nombres de las primeras dos subcuencas no corresponden con el nombre de sus cauces principales o la zonificación del IDEAM.

Además, de la localización de las estaciones hidrométricas, se utilizó un modelo digital de elevación MDE de resolución 12.5 m x 12.5 m de acceso abierto ALOS PALSAR (ALPSRP247700060, ALPSRP245220070 y ALPSRP245220060) captada el 18/sep/2010 para obtener la topografía de la cuenca. En la Figura 6-3 se muestra el MDE con efecto de sombras, las subcuencas y las estaciones hidrométricas que configuran la zona de estudio.

Figura 6-2. Cuencas definidas del caso de estudio según estaciones hidrométricas



Fuente: Elaboración propia

A través de la Figura 6-3, las cuencas delimitadas según el MDE con sus elevaciones máximas y mínimas. La Tabla 6-1, los parámetros morfométricos y la Figura 6-4 de curvas hipsométricas se efectúa la caracterización morfométrica de las tres cuencas de estudio.

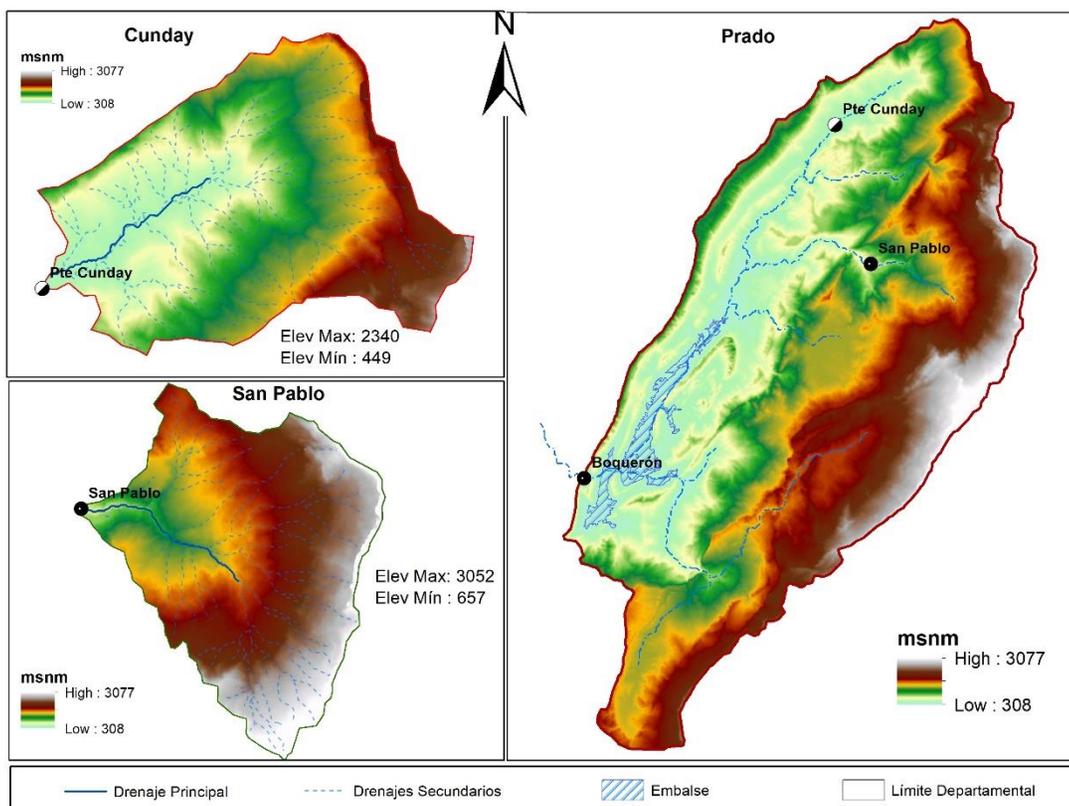
Cuenca Prado: su principal cauce es el río Prado, el cual es represado para formar el embalse Prado. El área de la cuenca hasta la estación Boquerón es de 1.616,4 km² y de la cuenca total hasta la desembocadura en el río Magdalena es de 1.698,2 km² (Cortolima, 2005). La curva hipsométrica muestra un río de mayor edad que los ríos Cunday y Cuindé, con una pendiente

media del 3 %. Presenta una baja densidad de drenaje que podría deberse a formaciones fuertes en las rocas. Según el factor de forma es “ligeramente ensanchada” atenuando los picos que llegarían a alcanzar los caudales de un evento extremo. Además, el factor de compacidad muestra una cuenca “Oval, redonda a oval - alargada” que indica su menor concentración de volúmenes frente a una cuenca totalmente redonda.

Subcuenca Cunday: se localiza en la parte norte central y posee un área de 130 km². Su elevación máxima es de 2340 msnm y la mínima de 449 msnm. Esta diferencia de altura es recorrida por su drenaje principal, río Cunday, en alrededor de 23.7 km a una pendiente media del 8%. Como lo muestra su curva hipsométrica, ver Figura 6-4, el río Cunday desciende con una pendiente media tipo moderada hacia el valle del río Prado en dirección al embalse Prado (es decir, de norte a sur). En esta subcuenca predomina el paisaje de montaña y/o cabeceras de los cerros, zona de captación de agua y de alta fragilidad hidrológica. Presenta una baja densidad de drenaje que puede deberse a formaciones fuertes en las rocas. Según el factor de forma es ligeramente ensanchada atenuando los picos que llegarían a alcanzar los caudales de un evento extremo. Además, el factor de compacidad muestra una cuenca Oval, redonda a oval - alargada que indica su menor concentración de volúmenes frente a una cuenca totalmente redonda.

Subcuenca San Pablo: localizada en la parte nororiental de la cuenca del río Prado a una elevación de máxima de 3052 msnm, una elevación mínima de 657 msnm y promedio de 1162 msnm tiene un área de 171.9 km². La diferencia de altitud es recorrida por su cauce principal, el río Cuindé, en alrededor de 18.9 km a una pendiente media del 13%. Esta subcuenca presenta el mismo tipo de paisaje que la subcuenca Cunday. Presenta una baja densidad de drenaje que podría deberse a formaciones fuertes en las rocas. Según el factor de forma es ensanchada atenuando los picos que llegarían alcanzar los caudales de un evento extremo. Además, el factor de compacidad muestra una cuenca “redonda a oval - redonda” que indica su mayor concentración de volúmenes frente a una cuenca totalmente “alargada”, como subcuencas de Cunday.

Figura 6-3. MDE y delimitación de las subcuencas



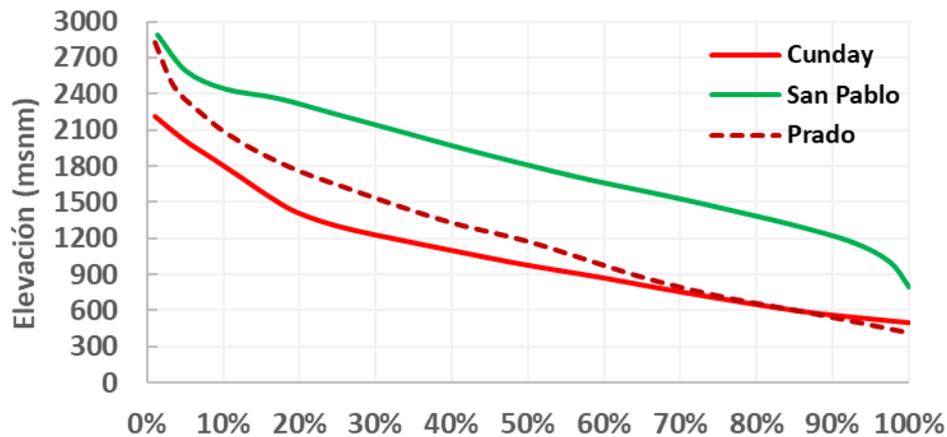
Fuente: modificado JAXA/METI (2010)

Tabla 6-1. Parámetros morfométricos de las áreas de estudio en cuenca del río Prado

Característica	Cunday	San Pablo	Prado
Área (km ²)	130.0	171.9	1616.4
Perímetro (km)	52.8	59.6	195.3
Ancho promedio (km)= (área/Long cauce)	5.4	9.10	19.6
Longitud cauce principal (km)	23.7	18.9	82.2
Pendiente media cauce principal (%)	8	13	3
Coefficiente de compacidad	1.3	1.2	1.36
Longitud axial	17.2	16.8	62
Factor forma	0.44	0.61	0.42
Suma longitud drenajes (m)	177.3	181.9	1959.2
Densidad de drenaje (km ⁻¹)	1.36	1.06	1.21
Pendiente media cuenca (%)	13.7	13.7	13.9
Número de orden	4	4	5
Cantidad drenajes	47	51	884
Altitud máxima (msnm)	2340	3052	3077
Altitud mínima (msnm)	449	657	308
Altitud media cuenca (msnm)	1016	1767	1162

Fuente: elaboración propia

Figura 6-4. Curvas hipsométricas de la cuenca del río Prado y sus subcuencas Cunday y San Pablo Prado



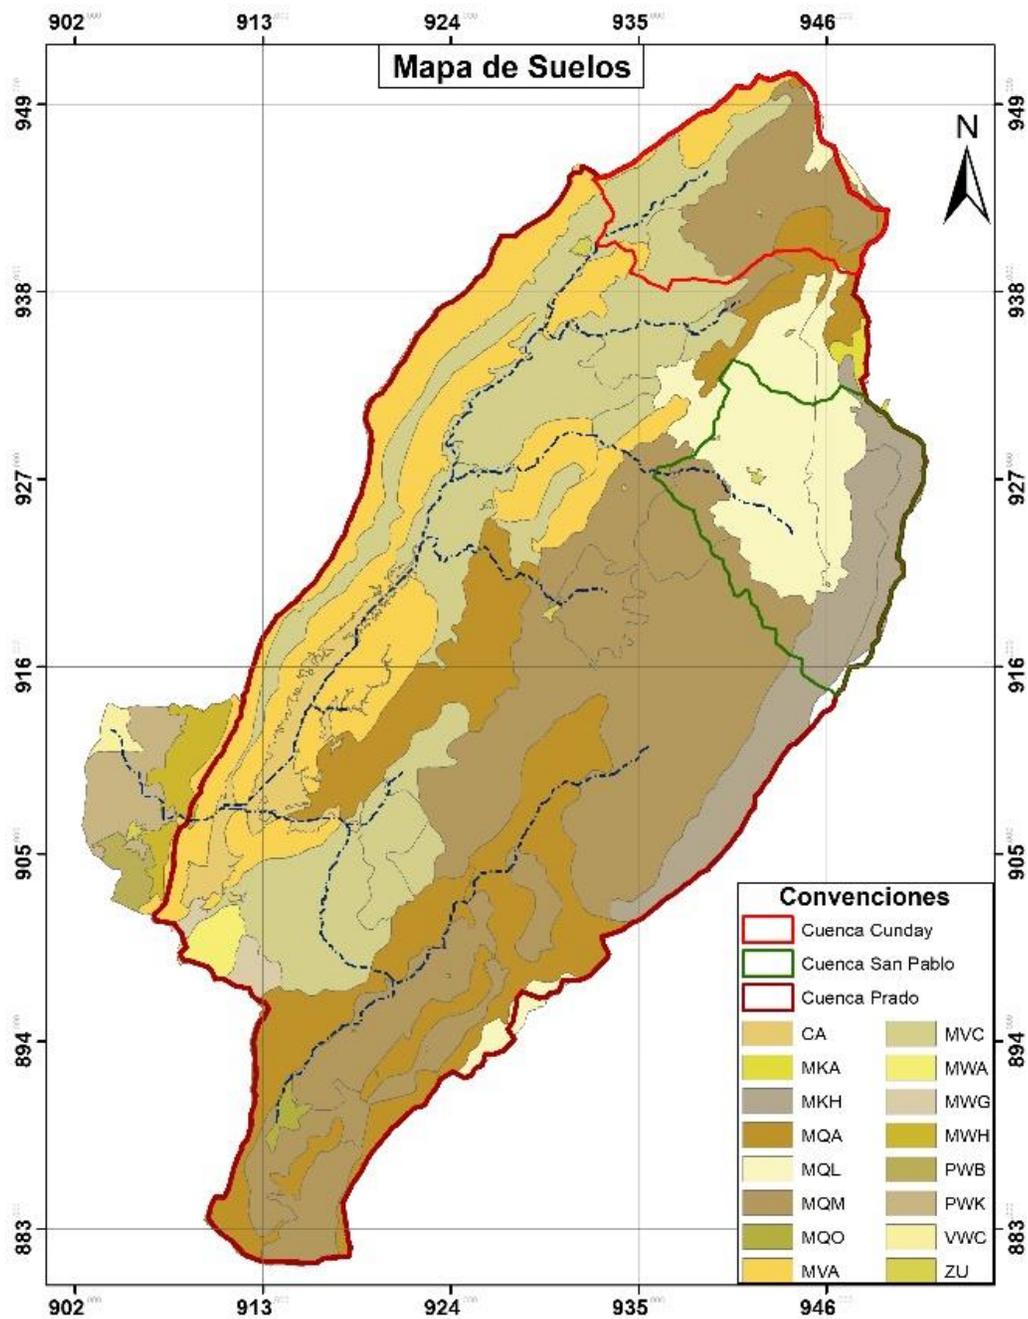
Fuente: elaboración propia

6.2. SUELOS

Los suelos de la cuenca del río Prado, Figura 6-5, son los correspondientes a los determinados en el Estudio General de Suelos y Zonificación de Tierras Departamento del Tolima (IGAC, 2004) escala 1:100.000. Los suelos que existen en la zona son MKA, MKH, MQA, MQL, MQM, MQO, MVA, MVC, MWA, MWG, MWH, PWB, PWK, VWC, CA y ZU, (ver Figura 6-5), que en su mayoría son suelos característicos del paisaje de montaña, en los que predominan tres de tipos de texturas: arcilloso, arcillolimoso y limoso.

Las definiciones y características de cada suelo son mencionadas en el anexo I.

Figura 6-5. Mapa de suelos



Fuente: Modificado (IGAC, 2004)

En la Tabla 6-2 se muestra en resumen la distribución en área y porcentaje de los suelos según el tipo de paisaje y clima. Se observa que el paisaje de montaña prevalece en un 95%. De este porcentaje predomina el clima Medio húmedo y muy húmedo con 52.4 % y el clima cálido húmedo con un área 33.8%.

Tabla 6-2. Distribución de suelos basado en el tipo de paisaje y clima.

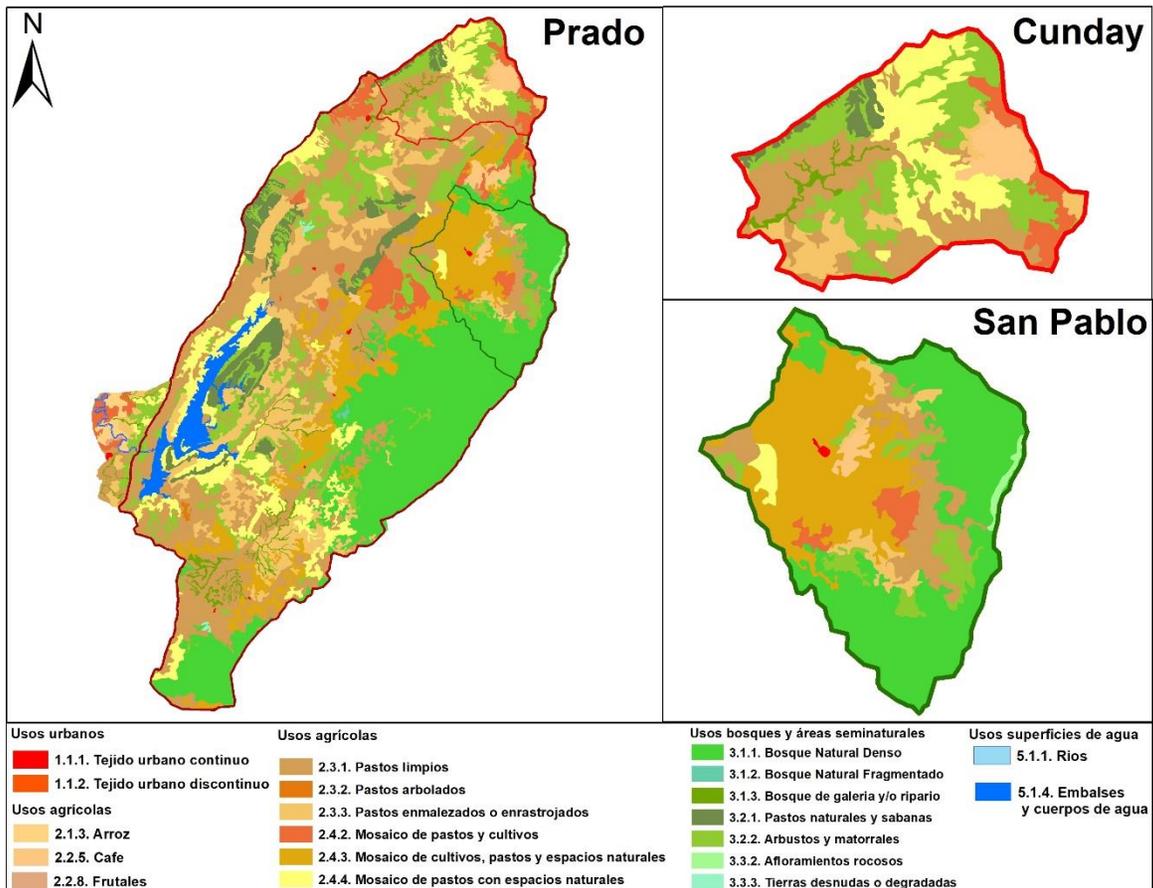
Paisaje	Clima	Área (ha)	%Área	Localización
Montaña	Frío húmedo y muy húmedo	10464,9	6.2	Icononzo y Villarrica
	Medio húmedo y muy húmedo	89153,1	52.5	Cunday, Dolores, Villarrica y parte Icononzo
	Cálido húmedo	57451,4	33.9	Cunday, Purificación y una unidad en parte de Dolores y Prado
	Cálido Seco	4078,3	2.3	Dolores, Prado y Purificación
Piedemonte	Cálido Seco	3855,8	2.3	Prado y Purificación
Valle	Cálido Seco	502,1	0.3	Margen oriental del río Prado
Zonas urbanas, embalse e isla			2.5	
Total		165505,8	100.	

Fuente: Modificado de Cortolima (2005)

6.3. COBERTURAS DE SUELO

Las coberturas de suelo corresponden al material físico o biofísico ubicado sobre la superficie de la tierra. Allí se describen elementos como vegetación, afloramientos rocosos, cuerpos de agua y usos antrópicos. Para el presente estudio se utilizó el mapa de coberturas del POMCA de Cortolima realizado en 2005 a partir de 1.492 fotografías aéreas que fue contrastado con visitas de campo de parte de la misma institución, la Universidad del Tolima y la Secretaría de Desarrollo del departamento. Los resultados de la interpretación fueron presentados según metodología *Corine Land Cover* en Colombia del IDEAM, ver Figura 6-6.

Figura 6-6. Mapa de coberturas vegetales Corine Land Cover



Fuente: modificado de Cortolima (2005)

Toda el área de la subcuenca Cunday está cubierta por 8 tipos de coberturas: pastos limpios 27%, arbustos y matorrales 26%, mosaico de pastos con espacios naturales 21%, pastos enmalezados o enrastrajados 8%, mosaico de pastos y cultivos 6%, café 6%, pastos naturales y sabanas 4% y bosque de galería y/o ripario 2%. En la subcuenca San Pablo imperan ocho coberturas que alcanzan un 99% del área y 1% correspondiente a tejido urbano y afloramientos rocosos donde no se presenta vegetación o cultivo alguno. La distribución es la siguiente: bosque natural denso 41.4%, mosaico de cultivos, pastos y espacios naturales 30%, y pastos limpios 11.6%, arbustos y matorrales 6.2%, pastos enmalezados o enrastrajados 4.0%, mosaico de pastos y cultivos 3.0%, mosaico de pastos con espacios naturales 1.4% y café 1.4%. Por último, la cuenca Prado, con once coberturas se cubren hasta un 99.6 % del total del área de la cuenca del río Prado, ellas son pastos limpios 24.6%, bosque natural denso 21.7%, arbustos y matorrales 12.1%, pastos enmalezados o enrastrajados 10.7%, mosaico de cultivos, pastos y espacios naturales 10.2 %, mosaico de pastos con espacios naturales 8%,

pastos naturales y sabanas 4.2%, mosaico de pastos y cultivos 3.5%, embalses y cuerpos de agua artificiales 2.4%, café 1.1% y bosque de galería y/o ripario 1.1%. El área restante está conformada por tierras desnudas, afloramientos rocosos, ríos, zonas urbanas y pastos.

6.4. CARACTERIZACIÓN HIDROCLIMATOLÓGICA

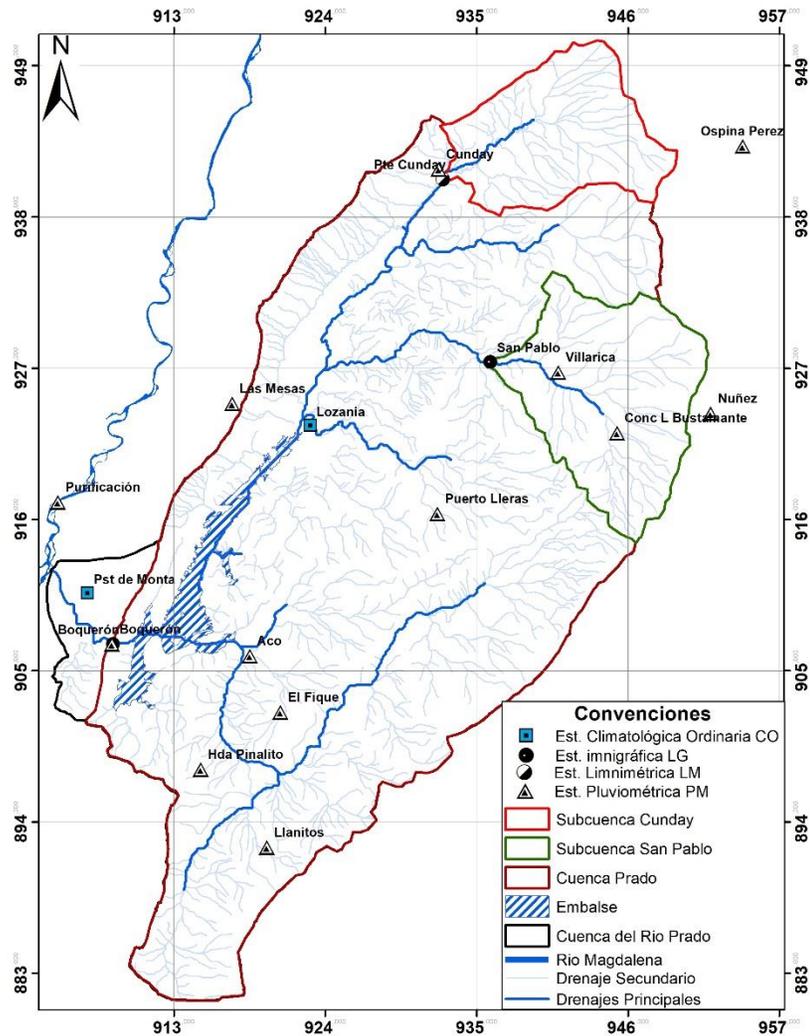
La caracterización hidroclimatológica de la cuenca del río Prado se efectuó mediante registro de estaciones pluviométricas, climatológicas ordinarias (incluyen pluviómetro, pluviógrafo y psicrómetro) e hidrométricas ubicadas dentro de la cuenca y en sus cercanías. En la Figura 6-7 se muestra la ubicación de las estaciones seleccionadas para esta caracterización y las características de cada una en la Tabla 6-3.

Tabla 6-3. Estaciones climatológicas cuenca río Prado

Código	Estación	Tipo	Depto	Municipio	Corriente	Lat.	Long.	Elev.	Instalada
21130010	Purificación	PM	Tolima	Purificación	Magdalena	3.84	-74.93	305	15/05/1958
21160030	Cunday	PM	Tolima	Cunday	Cunday	4.06	-74.68	448	15/09/1958
21160040	Aco	PM	Tolima	Prado	Negro	3.74	-74.81	378	15/02/1959
21160050	Pinalito	PM	Tolima	Prado	Negro	3.67	-74.84	827	15/02/1959
21160160	Llanitos	PM	Tolima	Dolores	Negro	3.62	-74.80	1,388	15/09/1983
21160170	El Fique	PM	Tolima	Prado	Negro	3.70	-74.79	1,040	15/09/1983
21160180	Pto. Lleras	PM	Tolima	Villarrica	Cuindé	3.84	-74.68	1,209	15/09/1983
21160200	Conc L. Bustamante	PM	Tolima	Villarrica	Cuindé	3.89	-74.57	1,613	15/08/1980
21165010	Pst. De Monta	CO	Tolima	Prado	Prado	3.78	-74.91	321	15/03/1987
21165030	Lozanía	CO	Tolima	Purificación	Qda. La Baja	3.89	-74.77	394	15/03/1972
21190330	Núñez	PM	C/marca	Cabrera	Qda. Negra	3.90	-74.51	1,950	15/08/1980

Fuente: modificado IDEAM

Figura 6-7. Estaciones climatológicas para precipitación



Fuente: Elaboración propia

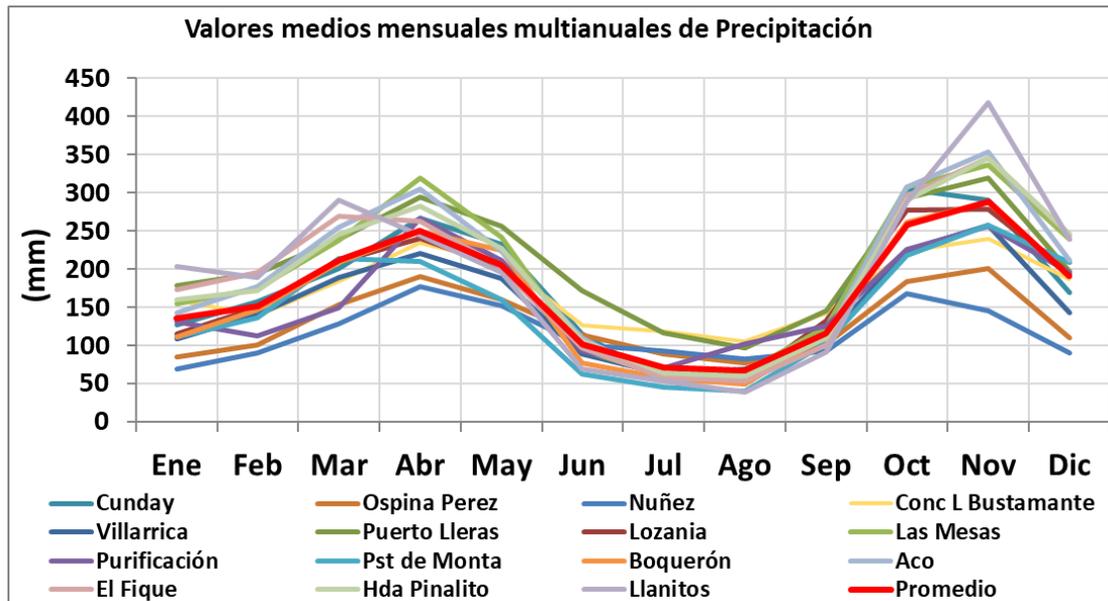
6.4.1. Precipitación

La precipitación de la cuenca del río Prado es analizada con series de datos de once estaciones de la red de estaciones del IDEAM. A partir de sus promedios mensuales multianuales (ver Figura 6-8) se observa un régimen de precipitaciones variado en magnitud, pero similar en los meses donde se presentan periodos secos y húmedos. En común para todas las estaciones se encuentran mayores precipitaciones en los meses de marzo, abril y mayo en el primer semestre el promedio es de 250 mm y en los meses de octubre, noviembre y parte de diciembre en el segundo semestre el promedio es de 280 mm. Los registros medios en la segunda parte del año son ligeramente superiores al primero. En los otros meses de

enero, febrero, junio, julio, agosto y parte de septiembre se presentan menores precipitaciones alcanzando los 50 mm por mes (ver Figura 6-8).

Según las once estaciones se observa un régimen de lluvias mensuales en los periodos húmedos presenta una diferencia aproximada de 150 y 200 mm y en los meses secos la diferencia es entre 80 a 100 mm (ver Figura 6-8).

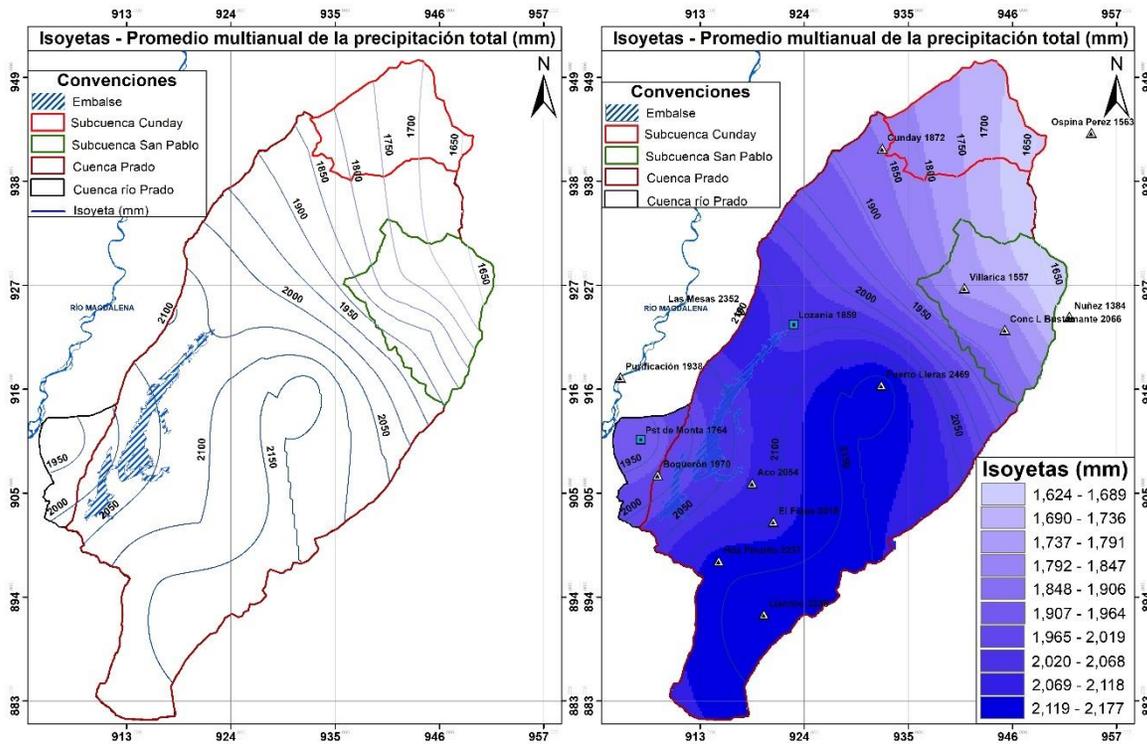
Figura 6-8. Precipitación media mensual multianual y su valor promedio, para el periodo de 1981-2012.



Fuente: Elaboración propia

La variación espacial de la distribución de la precipitación dentro de la cuenca Prado se analiza a partir de las isoyetas de precipitación total anual promedio multianual (ver Figura 6-9). Al norte de la cuenca Prado, en los municipios de Cunday y Villarrica, sobre las subcuencas Cunday y San Pablo se registra un rango de precipitación entre 1650 -1900 mm y 1650 – 1950 mm, respectivamente. La zona sur oriente en límites de los municipios de Dolores y Villarrica, se presentan las mayores precipitaciones aproximadamente 2100 mm frente a 2000 mm sobre la zona sur occidental, la de los municipios de Purificación y Prado donde se localiza el Embalse y los 1950 mm sobre la desembocadura del río Prado al río Magdalena.

Figura 6-9. Distribución espacial de la precipitación promedio multianual (mm) (Isoyetas)



Fuente: Elaboración propia

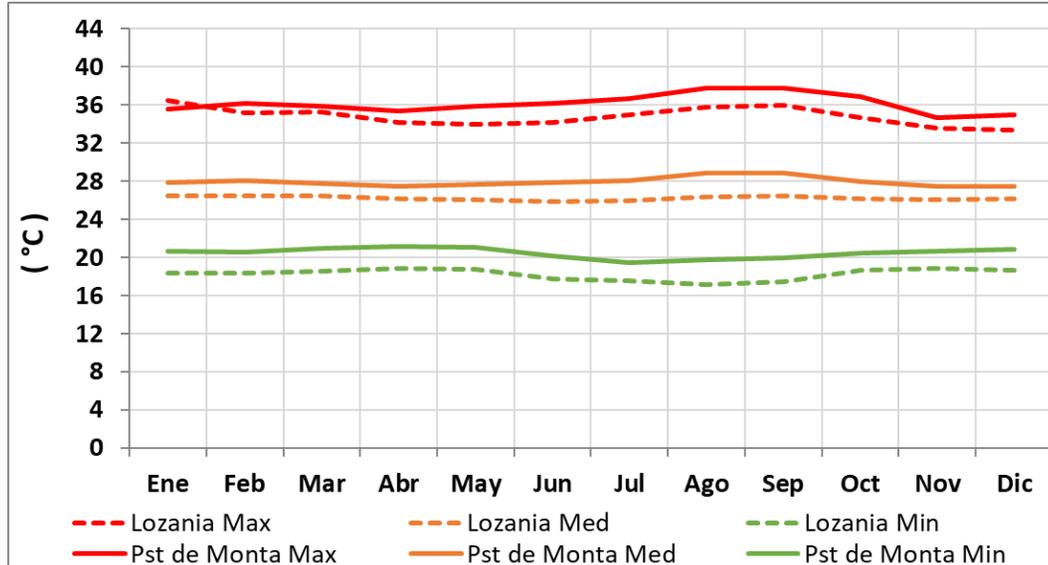
En la cuenca del río Prado el número de días con lluvias oscila entre 113 y 216 promedio multianual. Los sitios de mayor número de días se ubican al oriente en las laderas de la Cordillera Oriental. En contraste, los sitios cercanos al valle del río Magdalena presenta la menor cantidad de días con precipitaciones.

6.4.2. Temperatura

Las temperaturas dentro de la cuenca del río Prado fueron analizadas con las dos únicas estaciones climatológicas ordinarias ubicadas dentro de la cuenca. Las estaciones Pst. de Monta (400 msnm) y Lozanía (349 msnm) han registrado una temperatura promedio mensual multianual estable, cambiando entre 26°C y 28°C entre los meses secos y lluviosos. Más, sin embargo, entre temperaturas máximas y mínimas promedio multianual se registran hasta 17°C de diferencia. Los valores máximos de temperatura están alrededor de 35 a 38 °C y los valores mínimos entre 18 y 21 °C. Cabe señalar que no hubo registros o estaciones sobre las zonas

altas de la cuenca y no se lograron describir sus temperaturas que deben ser menores basados en el gradiente térmico por la elevación.

Figura 6-10. Temperatura mínima, media y máxima de las estaciones Pst de Monta y Lozanía, a escala mensual



Fuente: Elaboración propia

6.4.3. Evapotranspiración Potencial - ETP

Es difícil su estimación desde observaciones ya que no hay estaciones del IDEAM que estimen la evaporación de tanque y luego la evapotranspiración. A nivel mensual multianual el IDEAM señala para la estación Llanito con elevación de 1.310 msnm una evapotranspiración potencial promedio mensual multianual de 106.6 mm y a escala anual de 1279.6 mm. En la Figura 6-11 se reflejan los valores estimados de evapotranspiración potencial utilizando la ecuación de Hargreaves (Hargreaves and Samani, 1985)(ver Ecuación 6-1) basada en la temperatura y la radiación solar para cada cuenca de interés. El promedio mensual multianual es de 141.9 mm, 113.8 mm y 115.3 mm para las cuencas Cunday, San Pablo y Prado, respectivamente.

$$ETP = K_g + R_s + (T_c + 17.8)$$

Ecuación 6-1

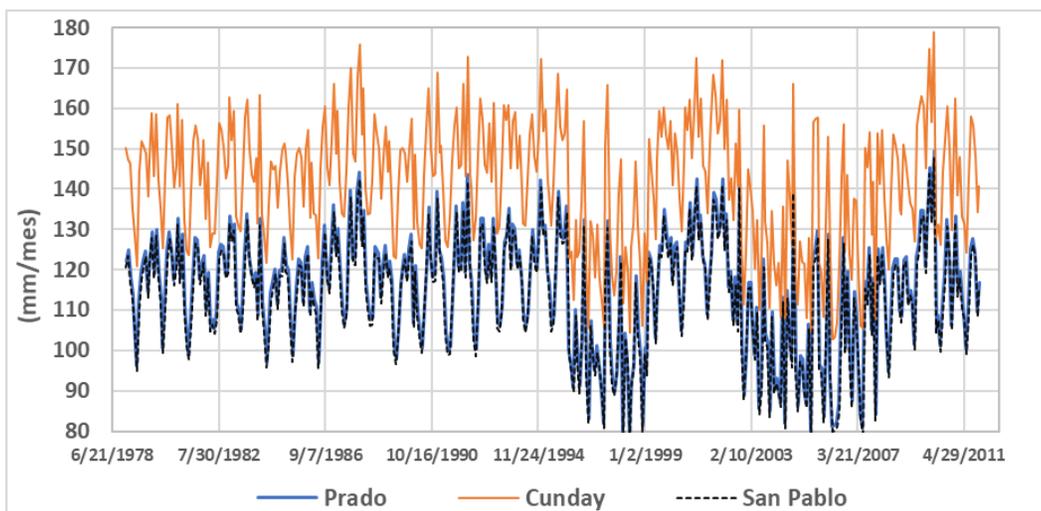
Donde ETP: evapotranspiración potencial

K_g : coeficiente de calibración

R_s : radiación solar

T_c : temperatura media

Figura 6-11. Evapotranspiración potencial mensual para cuenca del río Prado y sus dos subcuencas. Periodo 1981-2012



Fuente: Elaboración propia

6.4.4. Caudales

Los caudales fueron obtenidos de las estaciones Pte. Cunday, San Pablo y Boquerón de la red hidrometeorológica del IDEAM (ver Tabla 6-4). En la tabla se encuentran dos estaciones más que no han sido mencionadas hasta ahora porque no hacen parte del ensamble hidrológico. No se trabajó con ellas porque fueron instaladas posteriormente a 1981, año de inicio del ensamble y presentan mayor número de datos ausentes frente a las otras tres estaciones. Las series en sus escalas diarias se muestran en la Figura 6-12.

Tabla 6-4. Estaciones hidrométricas dentro de la cuenca Prado

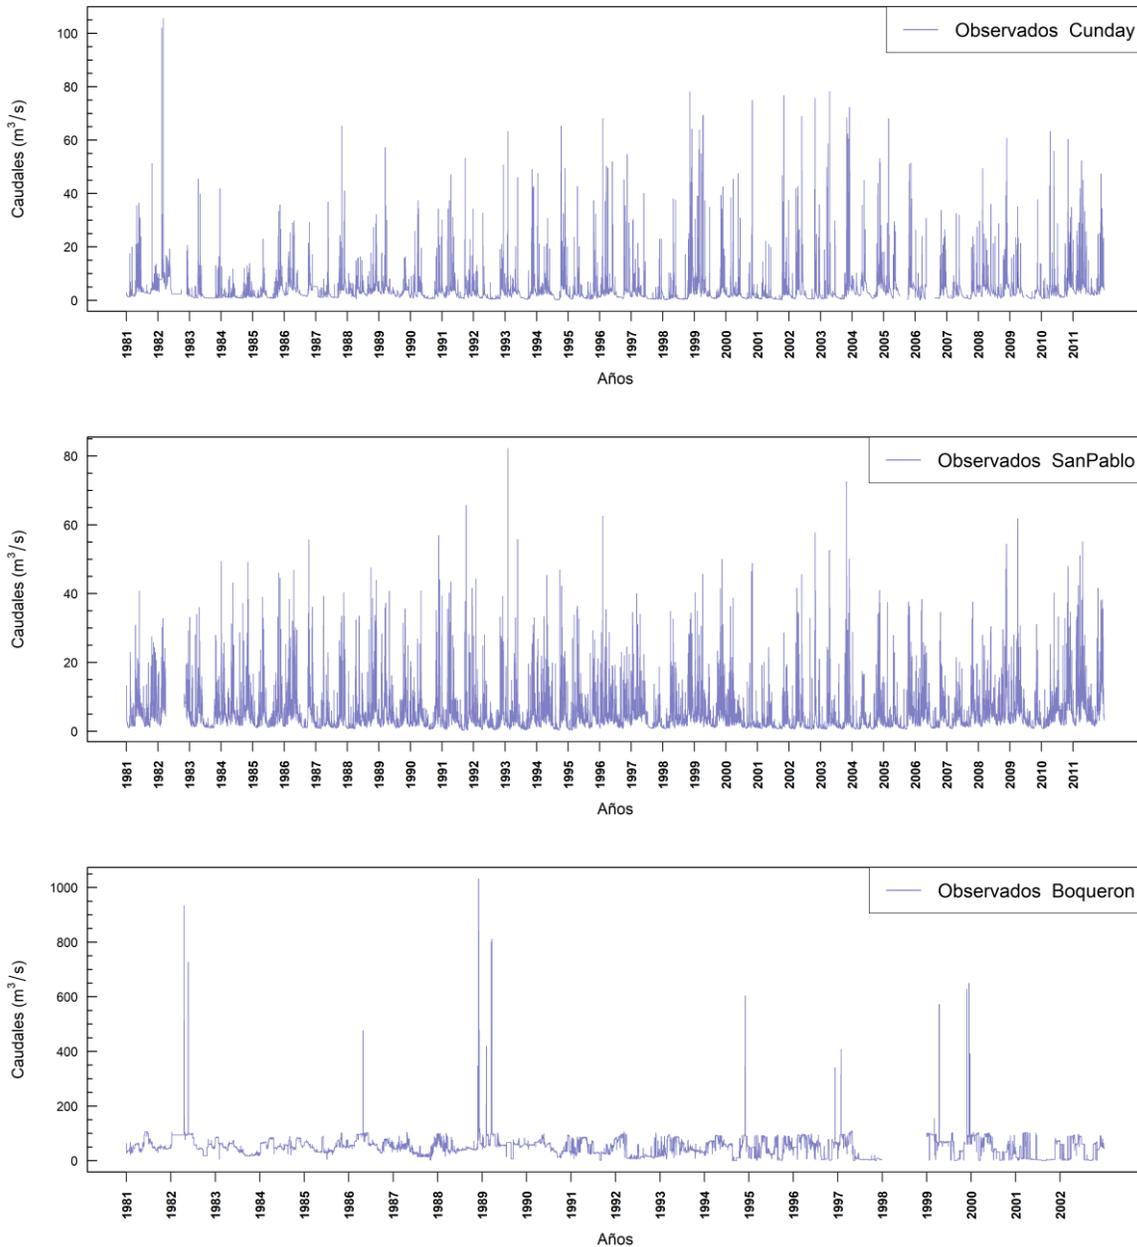
Código	Estación	Tipo	Depto	Municipio	Corriente	Lat.	Long.	Elev.	Instalada
21167020	Boquerón	LG	Tolima	Prado	Prado	3.75	-74.90	340	2/15/1959
21167050	Pte. Cunday	LM	Tolima	Cunday	Prado	4.06	-74.69	470	4/15/1971
21167060	San Pablo	HA	Tolima	Villarrica	Cuindé	3.93	-74.66	640	4/15/1971
21167090	Hda El Ruby	HA	Tolima	Cunday	Cunday	4.01	-74.72	640	8/15/1991
21167080	La Mora	HA	Tolima	Prado	Negro	3.73	-74.83	1425	10/15/1990

Fuente: modificado IDEAM

Tanto para escala diaria como mensual, las series analizadas corresponden a los años 1981-2011 en las estaciones Pte. Cunday y San Pablo, mientras que 1981 hasta 2002 en la estación Boquerón (Cuenca Prado) porque esta estación fue suspendida. A escala diaria las dos primeras estaciones deberían tener 11.322 datos de los cuales 11.013 tiene la serie de Pte.

Cunday (2.7% de faltantes) y 11.108 tiene la serie de la estación San Pablo (1.9% de faltantes) y la estación Boquerón debería tener 8.035 datos y se tienen 7.657 (4.7% de faltantes). A escala mensual las series de Cunday y San Pablo tienen una longitud de 372 datos sin faltantes y Boquerón tiene 264 datos sin faltantes.

Figura 6-12. Serie de caudales observados estaciones Cunday (arriba), San Pablo (centro) periodo 1981-2011 y Boquerón (abajo) periodo 1981-2002.



Fuente: Elaboración propia

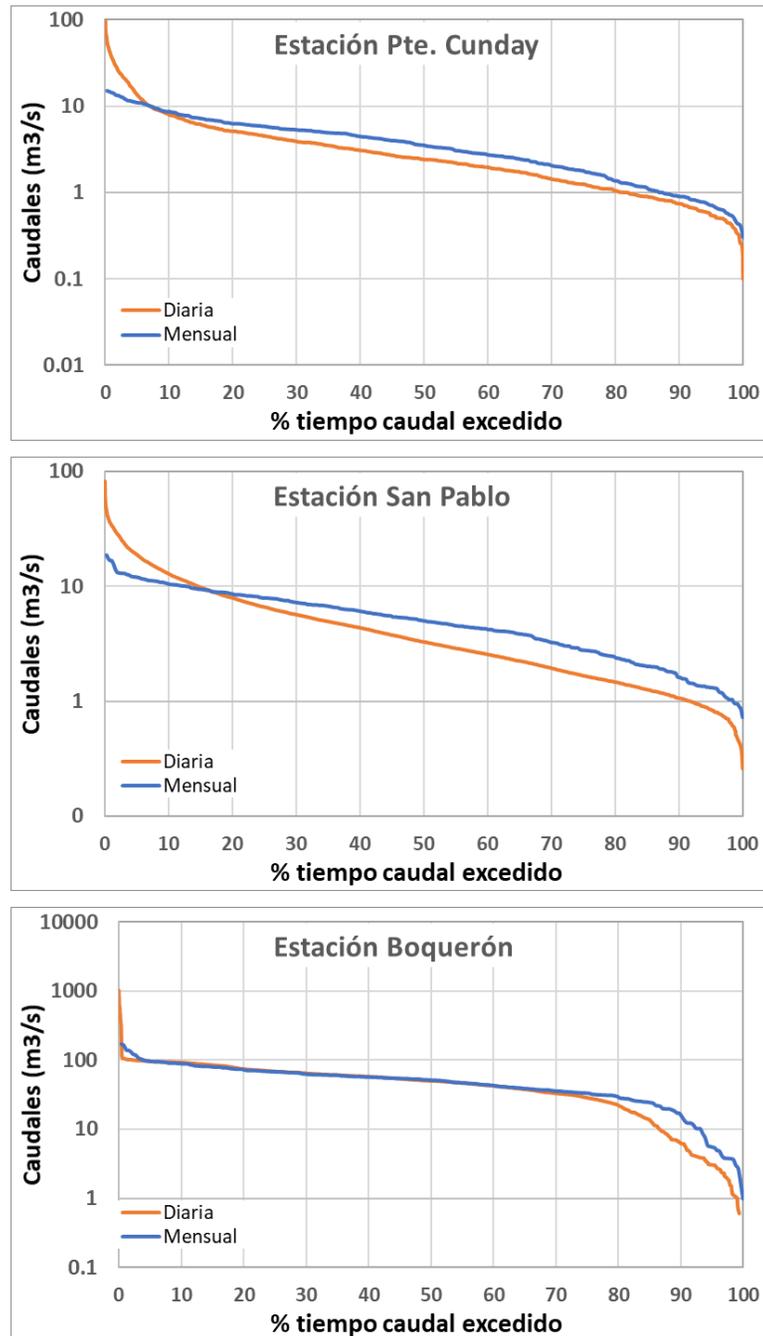
De las series en el periodo de estudio 1981-2011 para las estaciones Cunday y San Pablo y 1981-2002 para Boquerón se obtiene un caudal promedio de 4.2 m³/s, 5.6 m³/s y 51.6 m³/s, respectivamente. La estación Pte. Cunday ha registrado eventos diarios extremos con caudales de hasta 80 y 100 m³/s, mientras que su agregación mensual muestra eventos de máximo 15 m³/s. En la estación San Pablo se han registrado eventos de hasta 80 m³/s mientras que su registro mensual no supera los 19 m³/s. En la estación Boquerón se han presentado bastantes eventos cercanos a los 100 m³/s, inclusive algunos eventos más extremos han llegado muy cerca de 1000 m³/s. Esta estación recibe los caudales turbinados de la hidroeléctrica Prado. Los registros mensuales extremos no superan los 150 m³/s (ver Figura 6-12).

La Figura 6-13 presenta las curvas duración de caudales CDC a escala diaria para los periodos de análisis 1981-2011 estaciones Pte. Cunday y San Pablo, y 1981-2002 para la estación Boquerón. Las CDC en Pte. Cunday y San Pablo muestran una similitud hidrológica no solo por tener valores promedios que varían tan solo en 1.4 m³/s, sino que la pendiente alta de sus curvas hasta el percentil 90 aproximadamente señalan que son cuencas de alta montaña, existe alta variabilidad de los caudales y que su procedencia es especialmente de escorrentía superficial.

La estación Pte. Cunday presenta caudales superiores a 7.98 m³/s en el 10% del tiempo, de 2.41 m³/s en el 50% del tiempo (caudal mediano) y de 0.7 m³/s en el 90% del tiempo. Mientras que la estación San Pablo presenta caudales superiores a 12.88 m³/s en el 10% del tiempo, de 3.29 m³/s en el 50% del tiempo (caudal mediano) y de 1.07 m³/s en el 90% del tiempo.

La estación Boquerón presenta una CDC diferente porque tiene una pendiente menor porque representa una cuenca de media montaña y que tiene una regulación como la que ofrece el embalse, sus caudales extremos se presentan en menos de 1% del tiempo. Son eventos muy puntuales del manejo del embalse. Esta estación presenta caudales superiores a 93 m³/s en el 10% del tiempo, de 50 m³/s en el 50% del tiempo (caudal mediano) y de 6.3 m³/s en el 90% del tiempo.

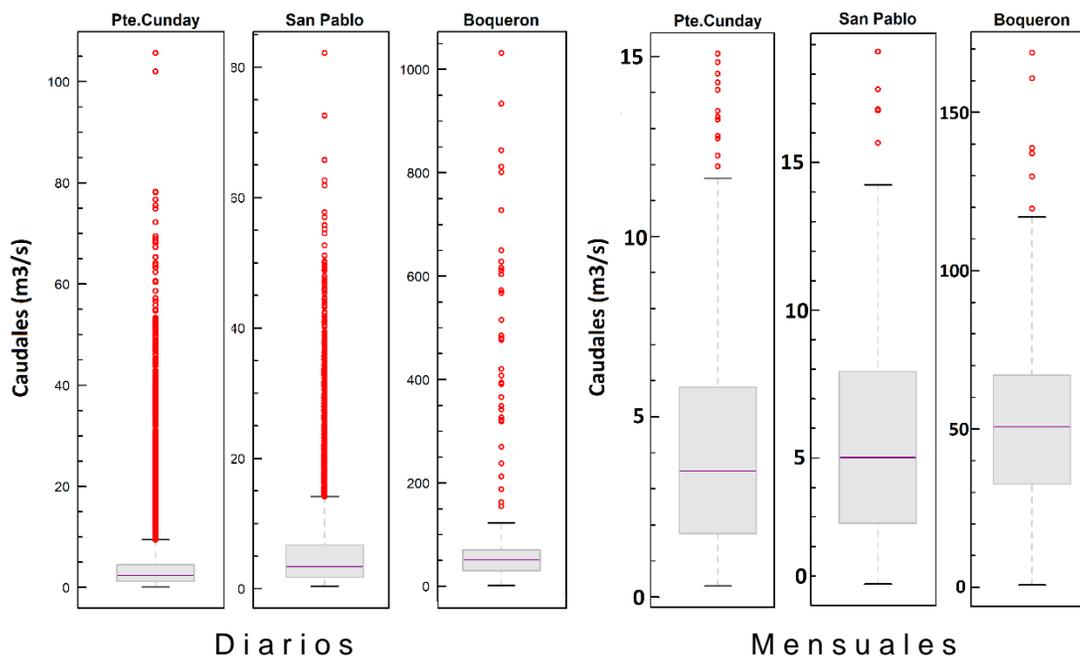
Figura 6-13. Curvas duración de caudales de registros diarios y mensuales de las estaciones Pte. Cunday, San Pablo y Boquerón



Fuente: Elaboración propia

El diagrama de cajas de la Figura 6-14 muestra la variabilidad de los caudales frente al promedio y los cuartiles 25% y 75% en las tres cuencas, particularmente en Cunday. A diferencia de la escala mensual en donde la variabilidad obviamente disminuye.

Figura 6-14. Diagrama de cajas caudales diarios y mensuales estaciones Cunday, San Pablo (1981-2011) y Boquerón (1981-2002)



Fuente: Elaboración propia

6.4.5. Caracterización de los servicios ecosistémicos

La cuenca del río Prado ofrece diferentes tipos de servicios ecosistémicos, incluyendo los de regulación, provisión, soporte y cultura.

Detallando sobre cuales servicios son ofrecidos puede decirse lo siguiente:

Regulación: clima local como el ofrecido por las coberturas, entre ellas los bosques de la zona alta y en cercanías del embalse. Un caso particular es el bosque de Galilea, que es un bosque de niebla. También, la captación de aguas de alcantarillados en 19 veredas. Otro servicio es permitir más de 2600 pozo sépticos. Regulación de crecidas mediante el embalse (Cortolima, 2005).

Embalse e hidroeléctrica Hidroprado

La Central Hidroeléctrica de río Prado – HIDROPRADO se ubica dentro de la cuenca del río Prado a una elevación media de 307 msnm. Fue construida entre 1961 y 1973. Consiste de 4 generadores para una capacidad instalada de 60 MW es administrada por CELSIA una filial de la Empresa De Energía Del Pacífico S.A. E.S.P, conocida como EPSA E.S.P.

El embalse ubicado entre los municipios de Prado, Purificación y Cunday tiene un área de 42 km² con una capacidad de 966 millones m³, pero un volumen útil de 506 millones de m³. La cota del vertedero de excesos se ubica en 363.20 msnm y la cota mínima de operación es de 348.70 msnm. La cota de la corona es de 371 msnm. La capacidad de evacuación del agua es de 1050 m³/s debido al aliviadero tipo *ski* con capacidad de descarga de 300 m³/s y mediante dos compuertas radiales de aproximadamente 6.7 m de diámetro se evacuan los restantes 750 m³/s. En el caso que la hidroeléctrica no alcance a evacuar los caudales mediante generación.

Provisión: agua potable para acueductos de 114 veredas beneficiando más de 5.000 familias mediante un poco más de 350 quebradas, 30 ríos y 80 humedales. Además, el embalse aporta 12 m³/s a la Asociación de Usuarios del Distrito de Adecuación de Tierras de mediana escala del río Prado ASOPRADO (Cortolima, 2005).

Las principales actividades económicas de los municipios se presentan relacionadas con la elevación del terreno: la cuenca alta desde 1500 hasta los 2500 msnm, la cuenca media va entre 1000 y 1500 msnm y la cuenca baja en elevaciones menores de 1000 msnm. A partir de ellos, las situaciones económicas son las siguientes:

Producción de café, plátano, banano bocadillo, cítricos, maíz, frijol, yuca, pitahaya, tomate de guiso y árbol, plátano, cacao, caña panelera, mora arroz, además de ganadería de doble propósito y estanques para piscicultura.

Culturales: El servicio turístico producto del embalse es alto, CELSIA (2013) menciona que se ofrecen regularmente más de 150 empleos relacionados con la existencia del embalse y esa cifra aumenta en temporada de vacaciones y festivales. Existe una capacidad instalada en el sector hotelero superior a 2.000 personas que pueden disfrutar de descanso, práctica de deportes náuticos, pesca deportiva, caminatas ecológicas, natación y canotaje.

Soporte: hábitat para 181 especies faunísticas reconocidas y cercano a las 300 especies de flora (Cortolima, 2005).

7. RESULTADOS Y ANÁLISIS

Este capítulo muestra los resultados de la implementación de los modelos hidrológicos locales, las características de las series de los modelos hidrológicos regionales y globales, y especialmente, la construcción del ensamble hidrológico para la cuenca del río Prado siguiendo la metodología indicada en el numeral 5.

7.1. MODELOS HIDROLÓGICOS LOCALES

Se hace mención de los resultados de los modelos creados por el autor a través de los modelos SWAT y DL con la herramienta Keras. Cabe señalar que el periodo de tiempo de estas simulaciones es desde 1981- 2012 aunque el ensamble fue construido desde el mismo año de inicio, pero finalizando en 2011.

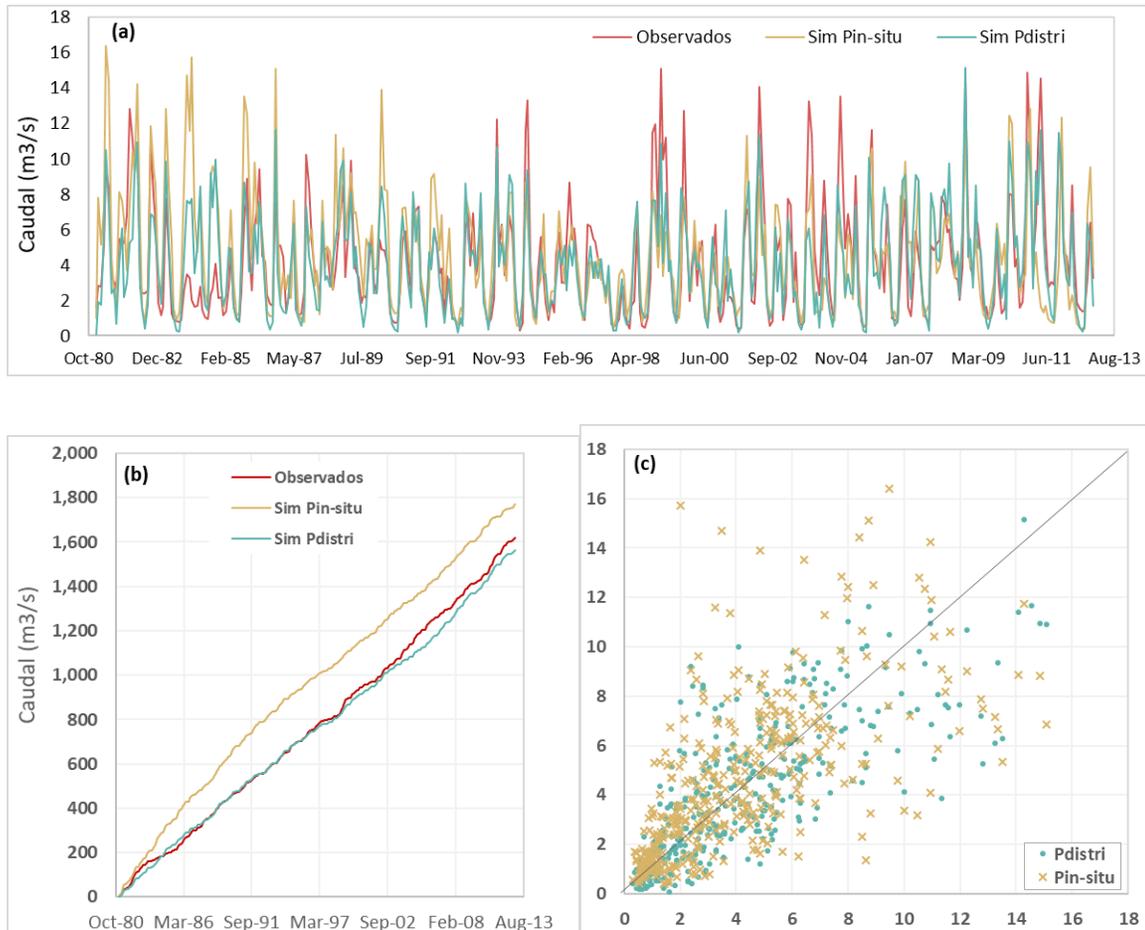
7.1.1. SWAT precipitación in-situ (Pin-situ) y precipitación distribuida (Pdistri)

El modelo hidrológico SWAT utilizado generó dos miembros para cada cuenca dentro del ensamble, que se diferencian en el forzamiento principal, la precipitación. Un modelo utiliza la precipitación de 11 estaciones in-situ (ver apartado precipitación caso de estudio) y el otro modelo utiliza la precipitación distribuida del proyecto *earth2Observe* (ver apartado del modelo SWAT en la metodología). Las siguientes figuras (Figura 7-1, Figura 7-2 y Figura 7-3) muestran los primeros resultados de las series de caudales simuladas para cada cuenca a escala mensual (372 meses), las curvas de caudales acumulados y la dispersión entre los dos modelos frente a los observados. En color café se muestran los caudales simulados con el forzamiento de precipitación in-situ, en verde los caudales simulados del forzamiento de la precipitación distribuida y en color rojo los caudales observados.

La Figura 7-1 corresponde a la cuenca Cunday, ambos modelos muestran que los caudales simulados representan el comportamiento de los observados con algunas consideraciones: SWAT tardó algunos años en ajustar sus magnitudes. Hacia la mitad de la hidrógrafa hace unas estimaciones muy ajustadas a los observados, pero después del año 1998 empieza a subestimar los caudales. Es probable que esto suceda no solamente por el modelo, sino que la escorrentía haya aumentado desde ese periodo haciendo que el modelo vuelva tomarle un esfuerzo su representación. El aumento de la escorrentía puede deberse a la modificación de la cobertura del suelo debido a la eliminación de los bosques en esta subcuenca.

Los dos modelos logran representar los caudales bajos casi en toda la serie, en contraste con los caudales altos y muy particularmente con los extremos máximos que no fueron bien simulados. Entre los dos modelos se evidencia que el modelo Pin-situ tiene menor desempeño que Pdistri. Este último modelo obtuvo NSE de 0.56 y KGE de 0.74 mientras que Pin-situ obtuvo NSE de 0.15 y KGE 0.58.

Figura 7-1. Caudales mensuales SWAT Cuenca Cunday. a) hidrógrafa b) curva acumulada de caudales y c) dispersión

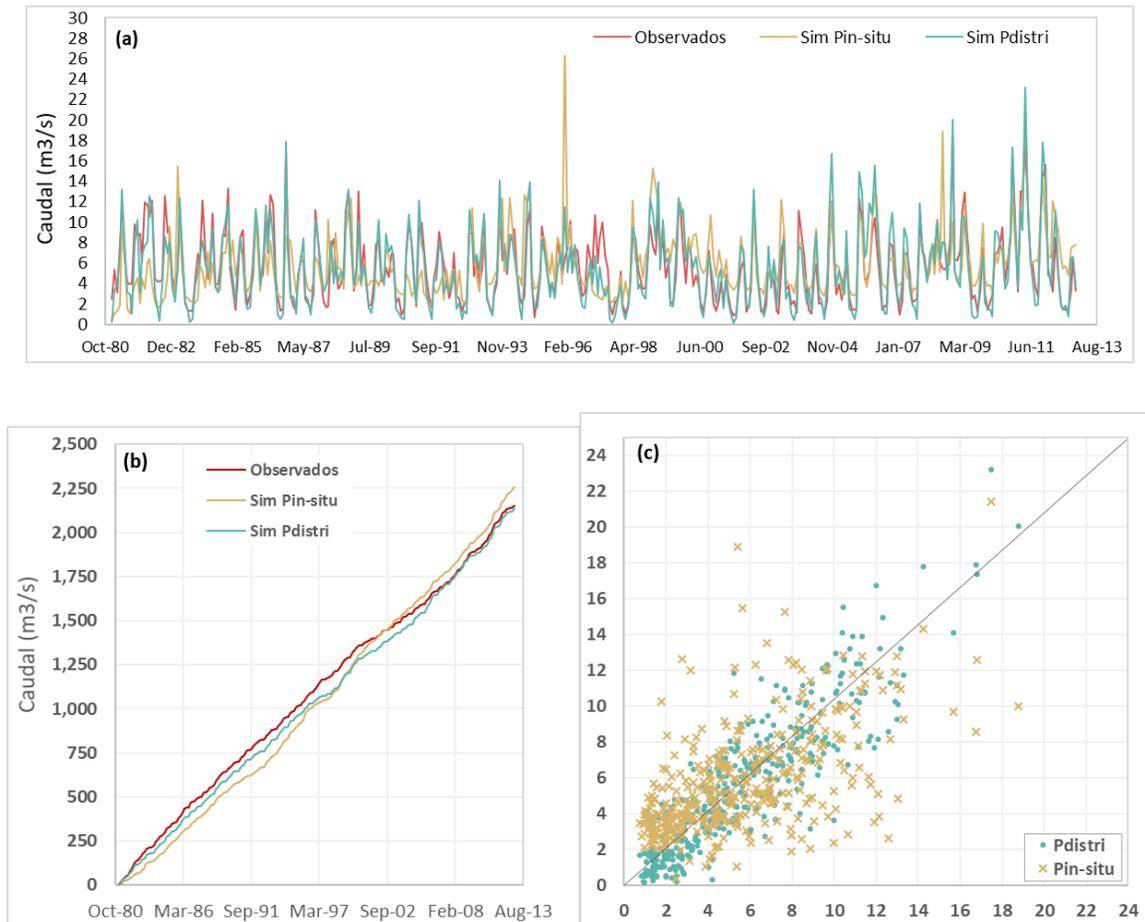


Fuente: Elaboración propia

La hidrógrafa generada con Pdistri para la subcuenca San Pablo tiene un buen desempeño tanto en caudales bajos y altos como en los medios alcanzando un NSE de 0.73 y KGE de 0.85. De hecho, las oscilaciones de las observaciones fueron captadas en mejor manera, por ejemplo, los valores bajos se representan con magnitudes cercanas a los 2 m³/s. Sin dejar de señalar que respecto a los caudales acumulados presentó subestimación gran parte del tiempo.

Las simulaciones Pin-situ oscilan más entre valores intermedios teniendo un desempeño mucho menor que Pdistri como lo indica su NSE -0.09 y KGE 0.44. Sus caudales acumulados inician en subestimación hasta el año 2000 donde empieza a aumentar sus magnitudes hasta ser superior a los observados terminando la simulación en sobreestimación.

Figura 7-2. Caudales mensuales SWAT Cuenca San Pablo. a) hidrógrafa b) curva acumulada de caudales y c) dispersión

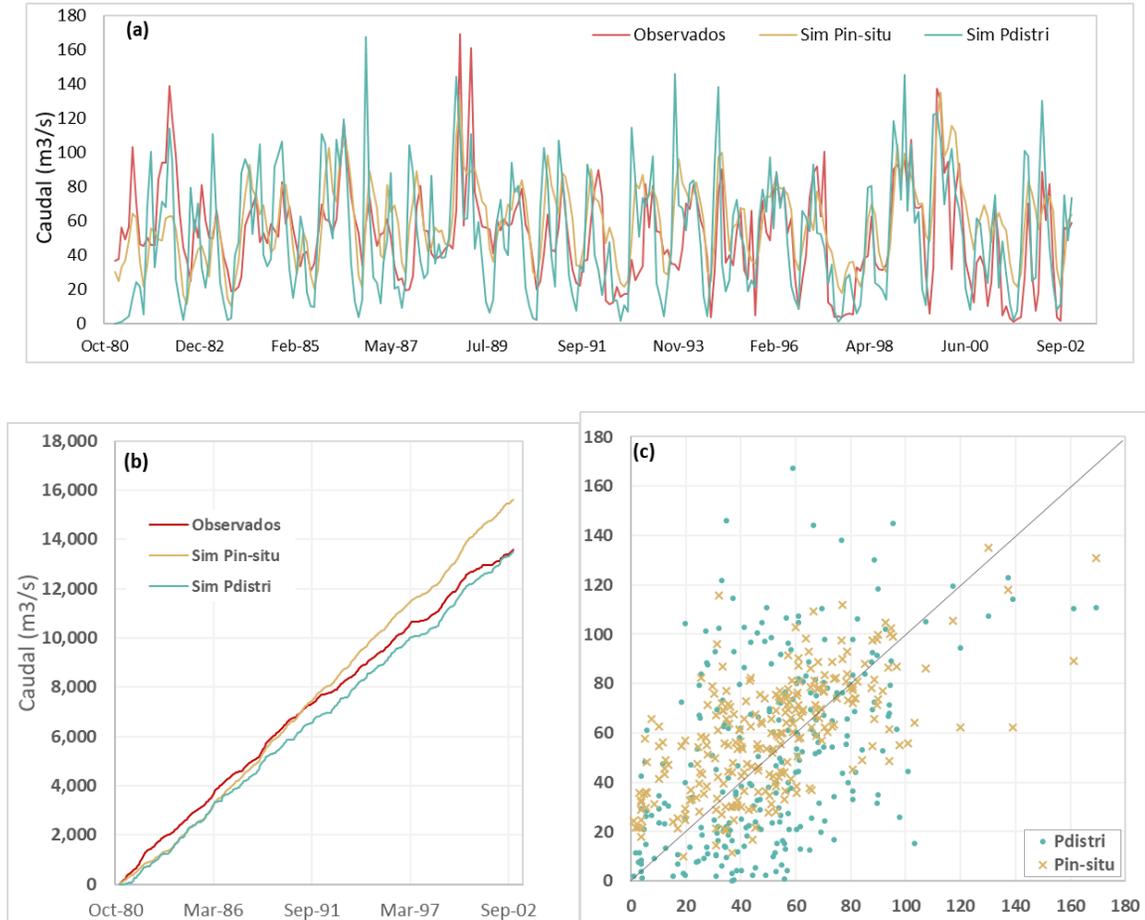


Fuente: Elaboración propia

Los caudales de la estación Boquerón que representan la cuenca del río Prado son subestimados por el modelo Pin-situ en la primera mitad de la serie y posteriormente, desde el año 1991 se inicia una sobreestimación. A diferencia del modelo con Pdistri que en toda la serie subestima los caudales. La dispersión de los caudales con Pdistri es mayor que Pin-situ

alcanzando NSE de -0.92 y KGE de 0.26 mientras que en Pin-situ el NSE es de 0.20 y KGE de 0.56.

Figura 7-3. Caudales mensuales SWAT Cuenca Prado. a) hidrógrafa b) curva acumulada de caudales y c) dispersión



Fuente: Elaboración propia

Desde los modelos desarrollados, la cuenca Prado es compleja de simular ya que no fue considerado el embalse Prado. No se añadieron al modelo los caudales turbinados o afluentes del embalse para que fuesen parte de la simulación. SWAT como modelo hidrológico permite agregar este tipo de embalses, pero no se realizó porque la series de tiempo existente ofrecida por XM (operador del sistema interconectado nacional y administrador del Mercado de Energía Mayorista de Colombia) existe desde 2007 cuando la estación Boquerón no estaba en operación. Es decir, de utilizar la serie 2007 – 2015 no se hubiese calibrado con Boquerón porque su registro finalizó en 2002.

La Tabla 7-1 resume la evaluación del desempeño a lo largo de toda la serie del modelo SWAT en las escalas mensual y diaria con las métricas NSE y KGE.

Tabla 7-1. Desempeño modelos SWAT Pin-situ y SWAT Pdistri

Escala	SWAT	Métrica	Periodo	Cunday	San Pablo	Prado
Diaria	Pin-situ	NSE	Calibración	-6.34	-5.85	-6.77
			Validación	-3.91	-4.69	-3.27
		KGE	Calibración	-0.93	-0.82	-0.92
			Validación	-0.45	-0.68	-0.39
	Pdistribuida	NSE	Calibración	-0.63	-0.66	-2.82
			Validación	-0.42	-0.78	-1.52
		KGE	Calibración	0.23	0.31	-0.19
			Validación	0.33	0.30	0.08
Mensual	Pin-situ	NSE	Calibración	0.15	-0.09	0.20
			Validación	0.33	0.58	0.39
		KGE	Calibración	0.58	0.44	0.56
			Validación	0.59	0.72	0.52
	Pdistribuida	NSE	Calibración	0.56	0.73	-0.92
			Validación	0.57	0.74	0.34
		KGE	Calibración	0.74	0.85	0.26
			Validación	0.76	0.8	0.67

Fuente: Elaboración propia

Con los resultados gráficos y numéricos se observa un mejor desempeño general del modelo con precipitaciones distribuidas con respecto al modelo con precipitaciones in-situ. Recordando que los dos modelos son totalmente similares excepto la precipitación. Se muestra la Figura 7-4 para identificar características de las precipitaciones que permitan revelar las diferencias en los desempeños de los mismos.

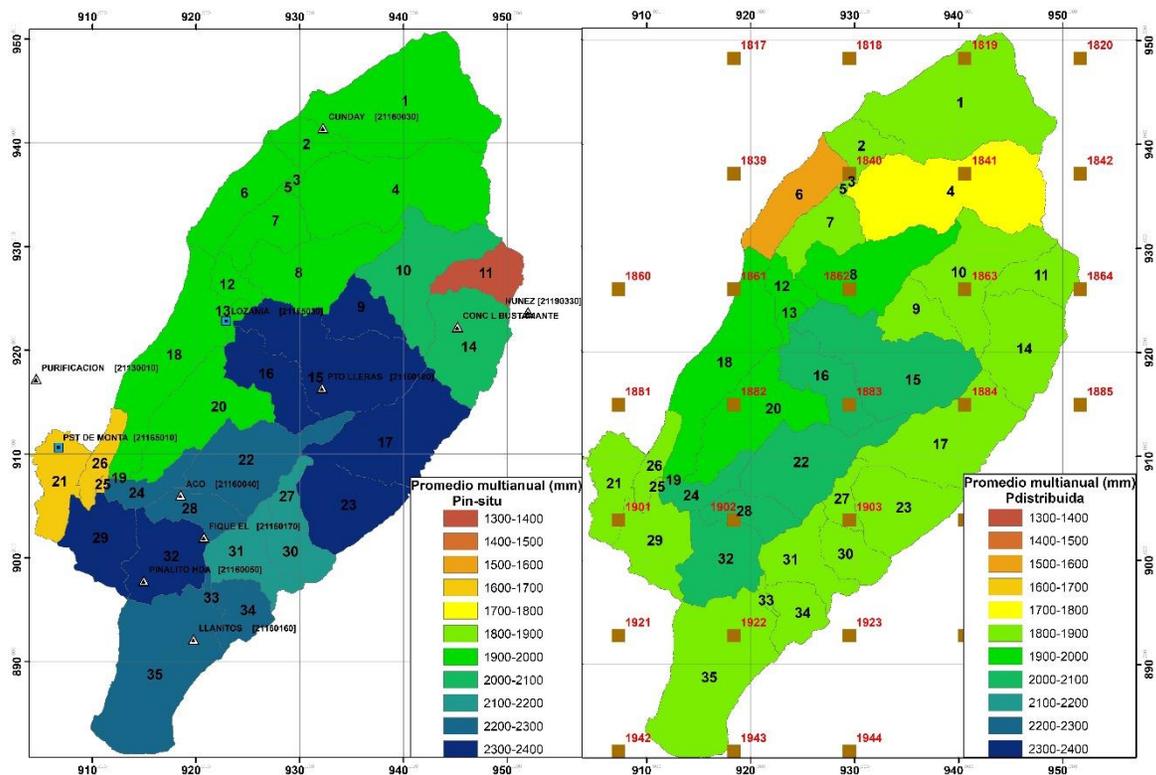
Los números dentro de los polígonos en la Figura 7-4 corresponden a una identificación de las subcuencas del modelo SWAT las cuales llegan a 35. En la imagen de la izquierda Figura 7-4 aparece las estaciones del IDEAM utilizadas y en la imagen de la derecha se localizan unos cuadros cafés (celdas) equidistantes que representan la malla distribuida de la precipitación y que este modelo de SWAT atribuye como “estación”.

Luego SWAT considera la proximidad de cada estación al centroide de la cuenca para asignarles a cada subcuenca una única estación por su cercanía. Allí se logra ver qué manera de asignación de las estaciones no es similar haciendo que la precipitación sea diferente en cada modelo.

También, el proceso de generación de la lluvia distribuida hace que las magnitudes y distribución de las lluvias anuales sean diferentes y a nivel diario también. Las leyendas de las dos imágenes de la Figura 7-4 tienen el mismo rango desde 1300 mm a 2400 mm, lo real en el rango de la precipitación distribuida es de 1585 – 2038 mm frente al rango de la precipitación in-situ que va desde 1374 a 2330 mm.

A pesar de que la lluvia anual de Pin-situ corresponde con los datos observados su ajuste en el modelo SWAT no fue fácil, requirió un mayor número de iteraciones durante la calibración con respecto a Pdistri en la construcción del modelo.

Figura 7-4. Precipitación total promedio multianual determinada por SWAT. Pin-situ (Izq) Pdistri (Der)



Fuente: Elaboración propia

7.1.2. Deep Learning Keras evaluado con las entradas propuestas por Brochero (2013) y De Vos (2013)

El enfoque de la modelación es de caja negra mediante una red neuronal profunda tipo red neuronal prealimentada (en inglés *Feed-Forward Network*) ejecutada en la herramienta KERAS con dos tipos de entradas para aprendizaje del modelo. Una manera fue la elaborada por el autor Brochero al utilizar cinco entradas (tres precipitaciones rezagadas y dos caudales rezagados). El otro tipo de entradas sugerido por el autor De Vos fue de tres entradas (precipitación, precipitación móvil y la evapotranspiración).

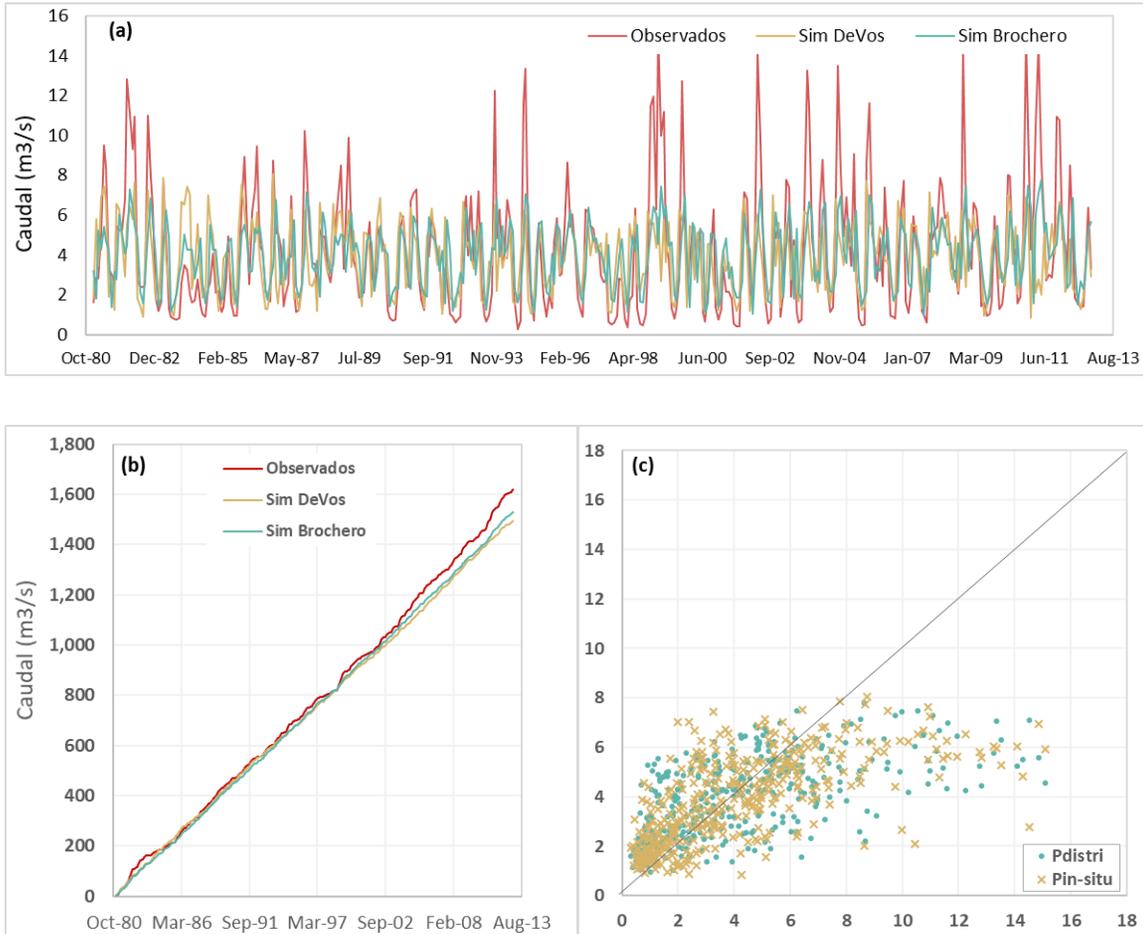
Habiendo mencionado brevemente la principal diferencia de los dos modelos, las siguientes figuras (Figura 7-5, Figura 7-6 y Figura 7-7) muestran los resultados de ellos frente a los observados en la escala mensual. Las líneas de color amarillo representan las simulaciones con las entradas De Vos y las líneas de color verde representan las simulaciones con las entradas de Brochero y la serie observada de color rojo.

Los modelos DL Keras en las tres cuencas para la curva de caudales acumulados desde muy cerca de su inicio muestran una tendencia a subestimar los caudales debido a que las simulaciones se comportan o parecen a los caudales medios observados sin llegar a los valores extremos tanto mínimos como máximos.

Para la cuenca Cunday, ver Figura 7-5, pasando el año 2000 se observa la subestimación de los caudales de manera similar a esta cuenca con el modelo SWAT, pero como se mencionó en ese momento, es posible que no sea únicamente incapacidad de representar los caudales por sí mismo, sino que las magnitudes de la escorrentía observada se incrementaron. Se hacen más recurrentes los eventos máximos.

Dentro de su comportamiento de valores medios se evidencia que KerasDeVos se acerca un poco más a los valores extremos (NSE=0.45 y KGE=0.49) mientras que KerasBrochero no predice esos valores extremos (NSE=0.35 y KGE=0.38).

Figura 7-5. Caudales mensuales Keras cuenca Cunday. a) hidrógrafa b) curva acumulada de caudales y c) dispersión

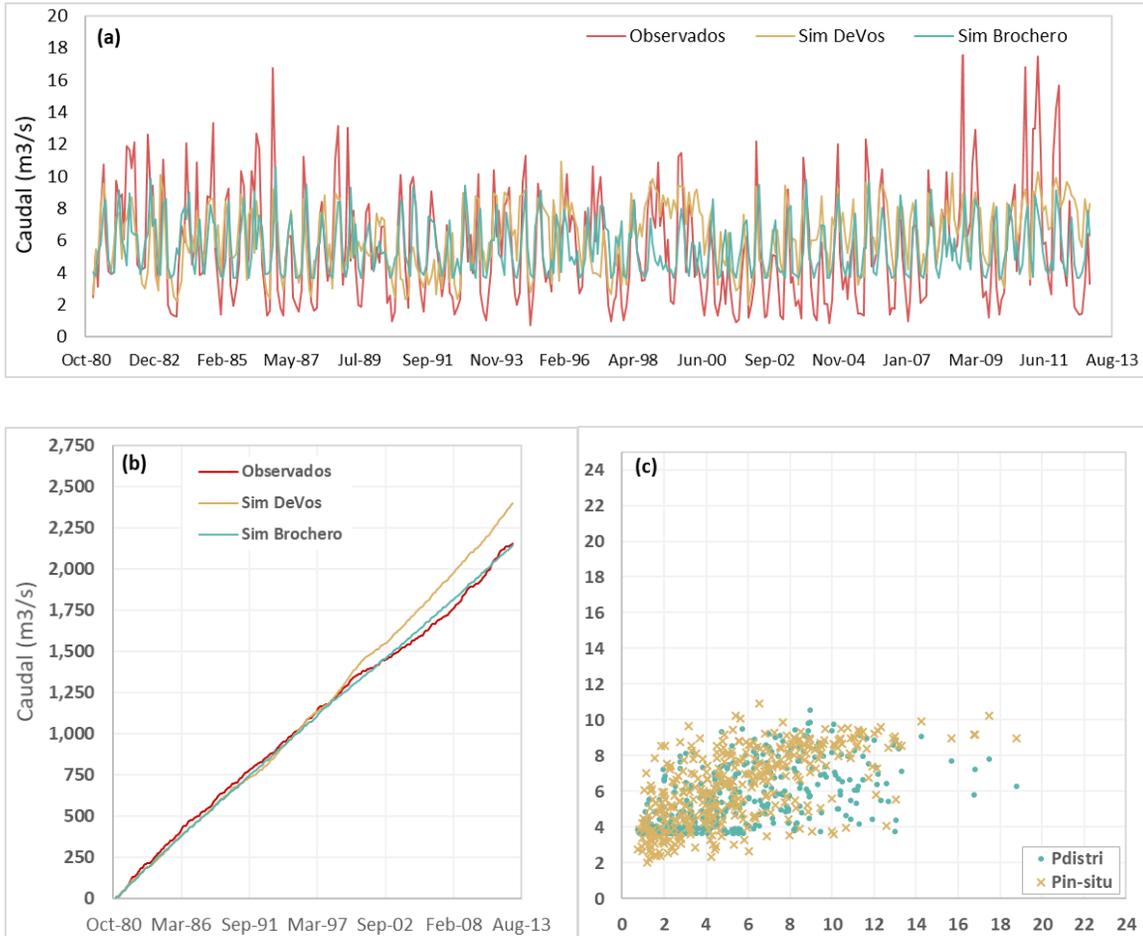


Fuente: Elaboración propia

En la cuenca San Pablo, ver Figura 7-6, las dos simulaciones se mueven entre valores medios y casi nunca ajustan a los valores extremos. En particular KerasDeVos (NSE=0.35 y KGE=0.48) presentó valores un poco más alejados de los valores medios mientras que Brochero no lo hizo tanto (NSE=0.30 y KGE=0.35). KerasDeVos en algunos se acerca más los caudales bajos.

Ambos modelos inician subestimando los caudales, pero después del año 1997-1998 se iguala según la curva de acumulación y posteriormente, KerasDeVos comienza a sobreestimar en esa acumulación mientras que KerasBrochero se mantiene más cerca de los observados.

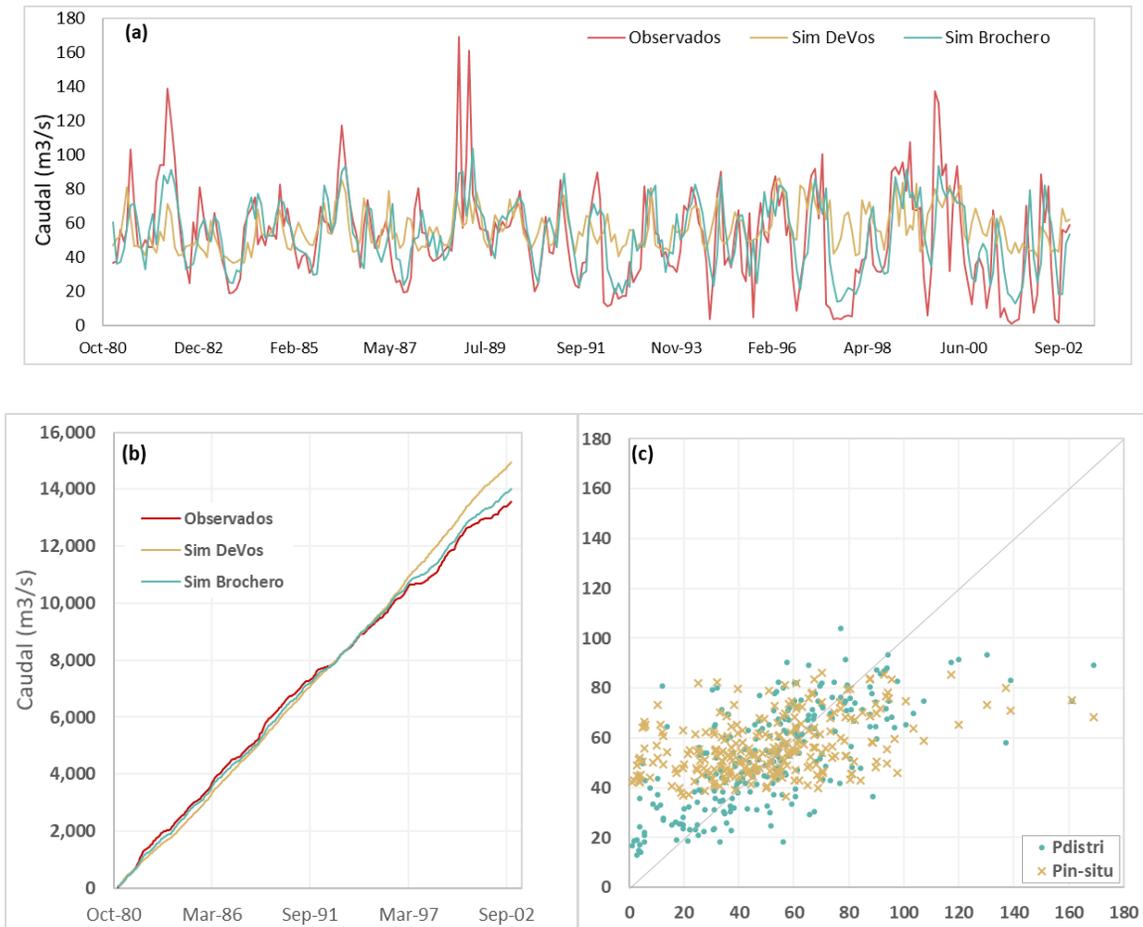
Figura 7-6. Caudales mensuales Keras cuenca San Pablo a) hidrógrafa b) curva acumulada de caudales y c) dispersión



Fuente: Elaboración propia

Los caudales simulados para ambos modelos inician con magnitudes similares y luego del primer año comienza una subestimación de los caudales acumulados que luego de la mitad de la serie se convierte en sobreestimación. KerasBrochero muestra una mayor oscilación de la serie ajustándose a los picos ($NSE=0.45$ y $KGE=0.57$), más no a los extremos y particularmente, se evidencia el rezago de la serie producto de las entradas que utiliza este modelo. Mientras que KerasDeVos muestra un comportamiento muy cercano a los caudales medios ($NSE=0.20$ y $KGE=0.23$). De hecho, nunca estima un caudal mayor a $90 m^3/s$ cuando algunas veces se presentan caudales superiores a $150 m^3/s$ Figura 7-7.

Figura 7-7. Caudales mensuales Keras cuenca Prado a) hidrógrafa b) curva acumulada de caudales y c) dispersión



Fuente: Elaboración propia

En términos generales los modelos representan los caudales medios producto de la estructura de un modelo basado en datos. En particular, el modelo KerasDeVos presentó en las dos primeras cuencas un comportamiento buscando más los valores extremos que KerasBrochero, aunque este último utilice entradas de variables rezagadas que deberían hacer que el modelo se comportara de manera más cercana a las oscilaciones de las observaciones, pero en la cuenca Prado se invirtió esa característica. Ahora es KerasBrochero el que sigue más el comportamiento de los observados.

El resumen de la evaluación del desempeño para ambos modelos en las dos escalas temporales se muestra en la Tabla 7-2 y posteriormente en las Tabla 7-3 y Tabla 7-4 del capítulo de evaluación de todos los modelos del ensamble.

La modelación hidrológica con técnicas de machine learning y específicamente de *Deep Learning* como se acabó de realizar acá ha venido desarrollándose cada vez más aumentando en número de resultados y la calidad de los mismos, e.g. Alizadeh (2018) encontró en NSE de 0.88 utilizando también FNN para estimación de caudales a escala mensual (450 meses aproximadamente) en una cuenca en Irán. Inclusive, utilizando otras seis redes neuronales NSE mínimo de 0.76. Significando que aún se puede intentar otras estrategias de DL para mejorar las estimaciones con este tipo de modelos basados en datos.

Tabla 7-2. Desempeño modelos DL KerasDeVos y KerasBrochero

Escala	Keras	Métrica	Periodo	Cunday	San Pablo	Prado
Diaria	De Vos	NSE	Calibración	0.16	0.14	-0.25
			Validación	0.10	0.23	-0.28
		KGE	Calibración	0.13	0.09	-0.87
			Validación	0.03	0.19	-0.65
	Brochero	NSE	Calibración	0.39	0.35	-0.16
			Validación	0.37	0.45	-0.20
		KGE	Calibración	0.45	0.43	0.10
			Validación	0.38	0.50	0.20
Mensual	De Vos	NSE	Calibración	0.45	0.42	0.18
			Validación	0.32	0.43	-0.87
		KGE	Calibración	0.52	0.49	0.20
			Validación	0.38	0.46	0.07
	Brochero	NSE	Calibración	0.35	0.33	0.49
			Validación	0.28	0.29	0.47
		KGE	Calibración	0.42	0.39	0.60
			Validación	0.33	0.32	0.54

Fuente: Elaboración propia

7.1.3. Comparación entre los modelos locales (mejor de swat y mejor de DL)

A continuación, se realiza una comparación a escala mensual y diario entre el mejor modelo de SWAT y el mejor modelo de DL Keras por cada cuenca para contrastar dos enfoques diferentes de modelación hidrológica.

Una primera comparación sería el proceso de calibración, mediante el modelo Keras está implícito en el entrenamiento de la red neuronal. No demanda un trabajo extra como en el caso de SWAT. Computacionalmente, en este caso de estudio, no se incurrió en gastos adicionales a un computador portátil personal de procesador 2.50GHz de 64 bit y memoria RAM de 8 GB tanto para entrenar la red neuronal como para calibrar SWAT.

El alistamiento de las series hidroclimatológicas es similar en los dos casos porque se requieren las precipitaciones y caudales en ambos modelos y temperaturas, humedad relativa, brillo solar, mapa de suelos, coberturas y topografía para el caso de SWAT.

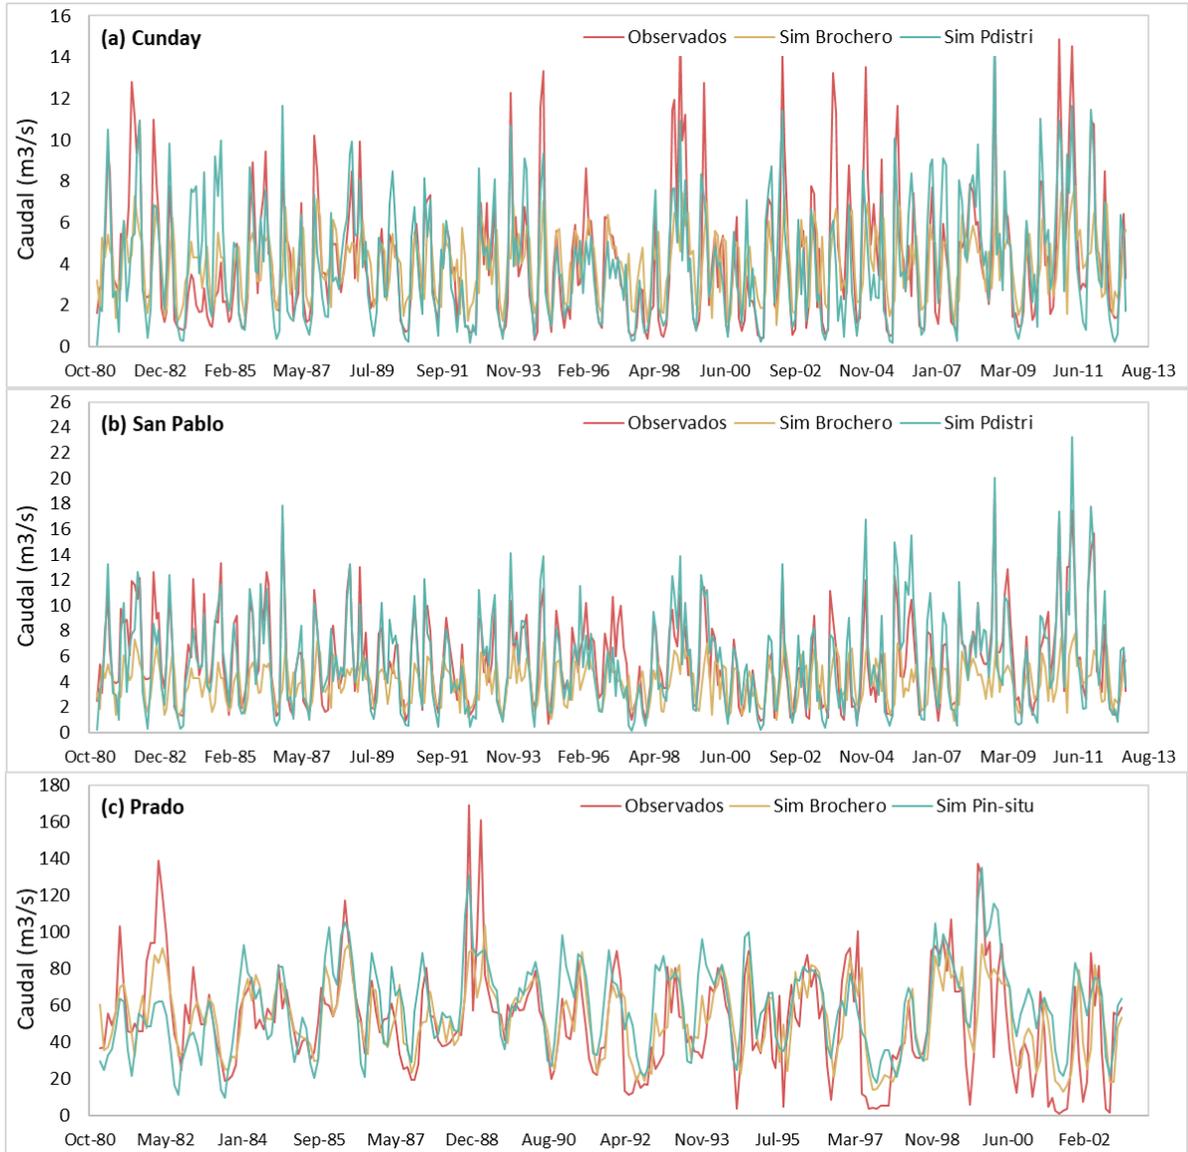
Por otro lado, relacionando el comportamiento de las series a escala mensual, ver Figura 7-8, la representación de SWAT es más ajustada que Keras siguiendo el comportamiento de la serie observada más allá de los valores medios como si lo hace Keras en la cuenca Cunday (a), el cual tiende a subestimar los caudales.

El comportamiento en la cuenca San Pablo (b) es similar a Cunday, Keras subestima los caudales (NSE 0.42) y no se acerca tanto a los extremos como lo hace SWAT (NSE 0.73).

En la cuenca Prado (c) la métrica NSE de ambos modelos es muy similar 0.56 y 0.60, pero podría decirse que el modelo SWAT no corresponde en cierta manera con la realidad de la cuenca porque dentro de su construcción no se creó el “reservorio” para agregar las características del embalse y las condiciones de operación (caudales turbinados). En otras palabras, la hidrología en esta cuenca no está representada totalmente porque las suposiciones del modelo quedan a un lado cuando el embalse corta el flujo normal y hace rezagar la escorrentía (cuenca regulada). La represa modifica la naturalidad de la conversión hidrológica de lluvia en escorrentía en esa área. Aunque la calibración de la cuenca se realizó con la estación aguas abajo del embalse. Esta situación se presenta en ambas escalas temporales.

De hecho, los modelos Keras no incluyen expresamente los caudales turbinados. En esta cuenca Prado los caudales de entrenamiento corresponden a la estación Boquerón aguas abajo del embalse.

Figura 7-8. Series simuladas para cada cuenca del mejor modelo en Keras y en SWAT a escala mensual

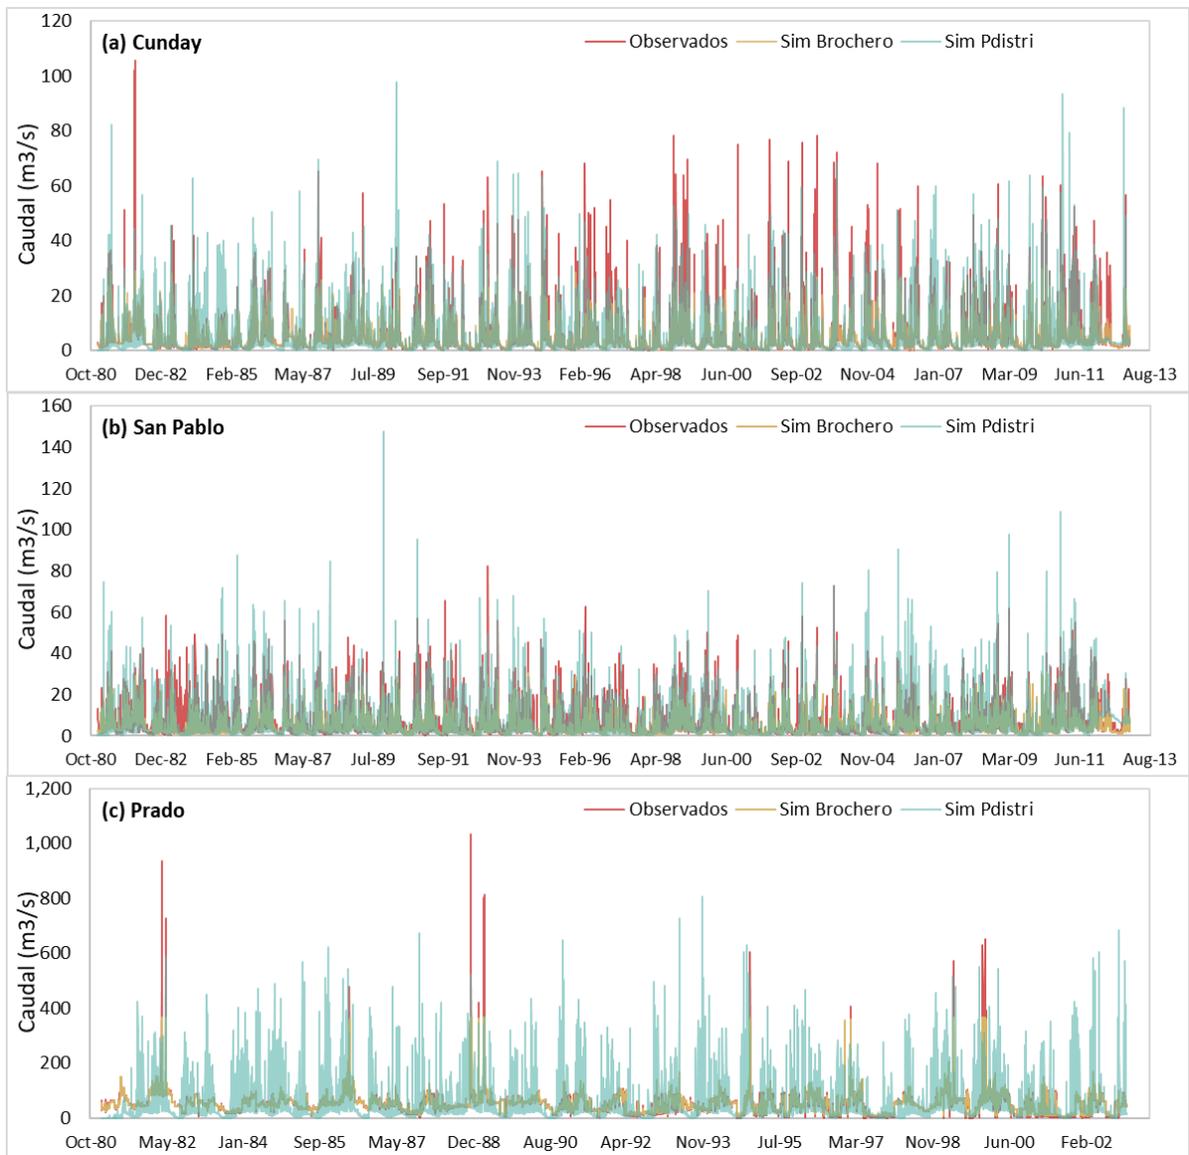


Fuente: Elaboración propia

En la Figura 7-9 se presentan las series de caudales observados y simulados para el mejor modelo Keras y mejor modelo SWAT para cada subcuenca a escala diaria. Los desempeños a esta escala son menores frente a la escala mensual. Caudales observados de color rojo, simulados en SWAT Pdistri de color verde y simulados KerasBrochero de color café. Estos últimos dos colores pueden verse diferente por su sobreposición.

En las tres cuencas/subcuencas SWAT busca ajustarse más a los eventos máximos, pero también sobreestima los caudales medios son sobreestimados comparado con KerasBrochero.

Figura 7-9. Series simuladas para cada cuenca del mejor modelo en Keras y en SWAT escala diaria

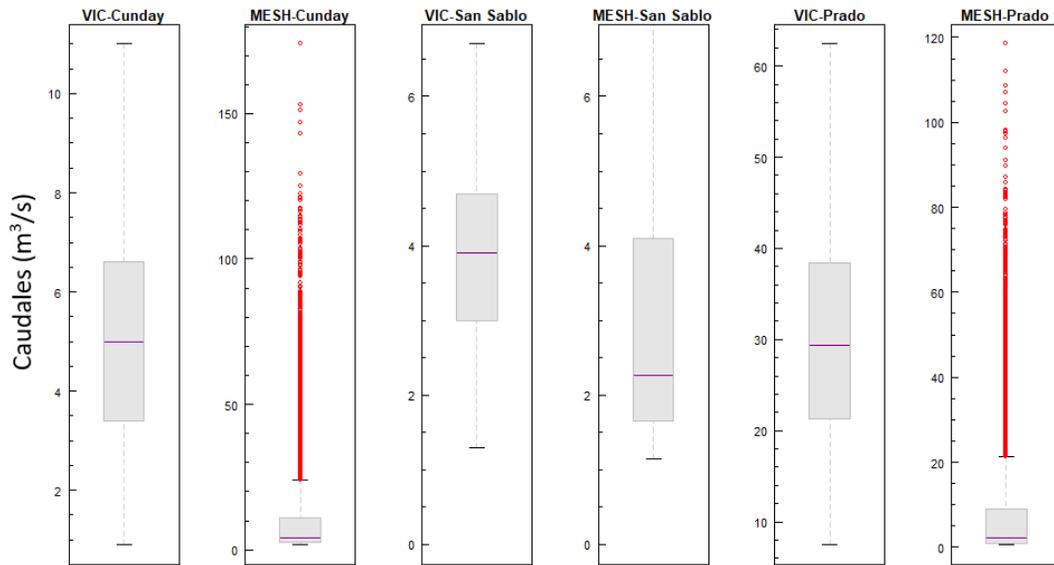


Fuente: Elaboración propia

7.2. MODELOS HIDROLÓGICOS REGIONALES

En este apartado los caudales de los modelos regionales son presentados mediante un diagrama de cajas (ver Figura 7-10) notar numéricamente el comportamiento de la misma mientras que las series son presentadas en el Anexo 2.

Figura 7-10. Diagrama de cajas modelos MESH y VIC escala diaria



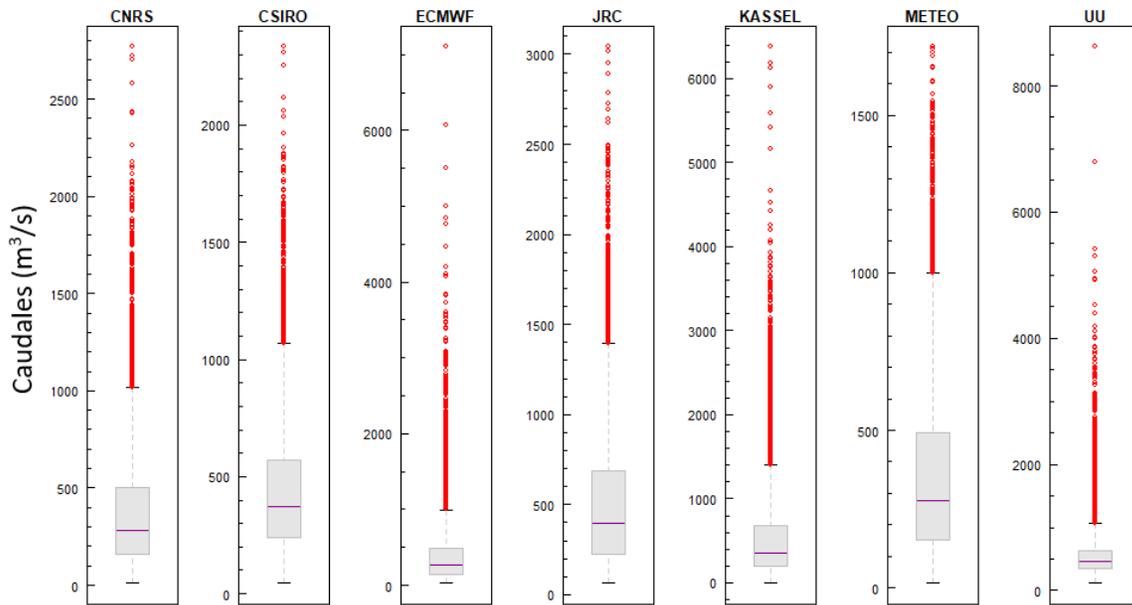
Fuente: Elaboración propia

7.3. MODELOS HIDROLÓGICOS GLOBALES

Al igual que los modelos hidrológicos regionales, los modelos globales se presentan mediante diagramas de cajas para analizar la variabilidad de la serie y sus magnitudes sin ver la hidrógrafa completa, las cuales son presentadas en el Anexo 2.

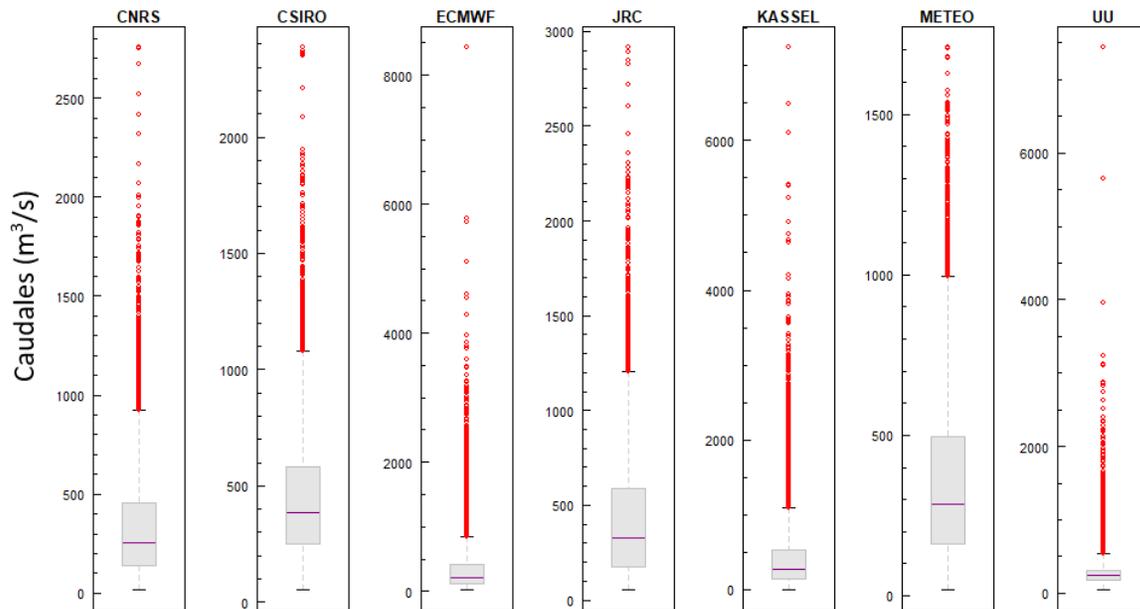
7.3.1. Escala 0.5°

Figura 7-11. Diagrama de cajas modelos globales escala diaria cuenca Cunday



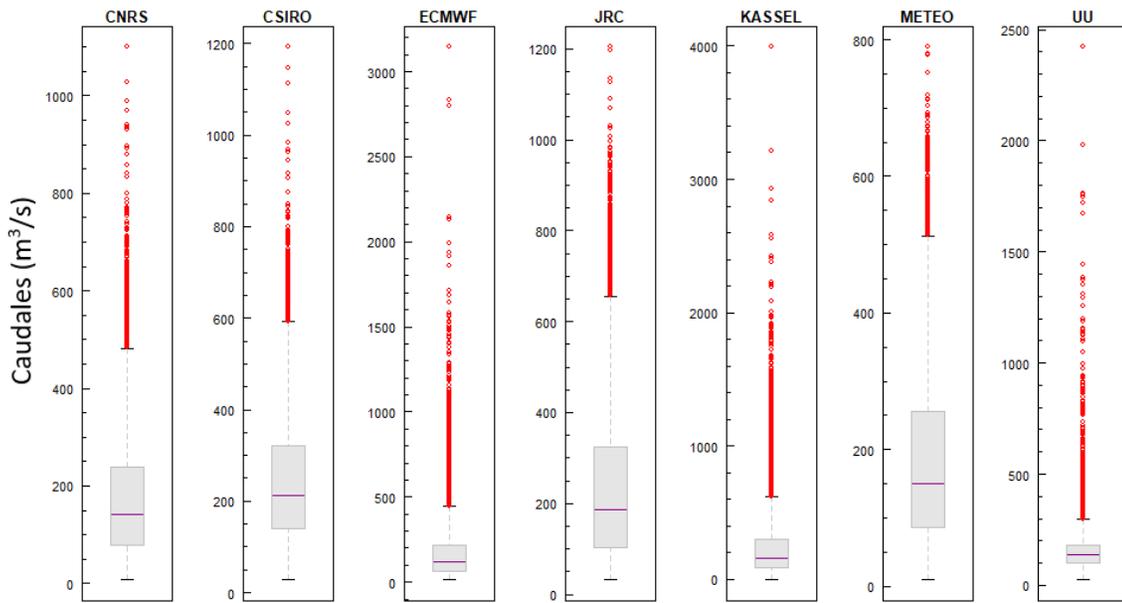
Fuente: Elaboración propia

Figura 7-12. Diagrama de cajas modelos globales escala diaria cuenca San Pablo



Fuente: Elaboración propia

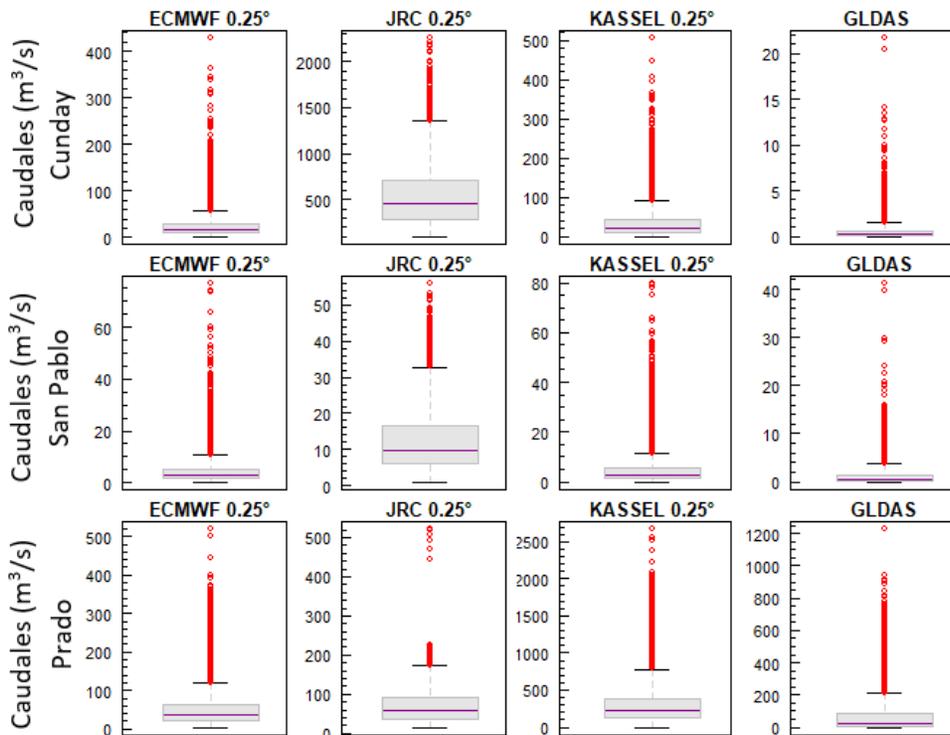
Figura 7-13. Diagrama de cajas modelos globales escala diaria cuenca Prado



Fuente: Elaboración propia.

7.3.2. Escala 0.25°

Figura 7-14. Diagrama de cajas modelos globales 0.25° escala diaria



Fuente: Elaboración propia

En términos generales los modelos por sus desarrollos u orígenes tienen magnitudes promedio altas en los caudales. En el caso de la cuenca Prado los modelos globales de 0.25° tienen magnitudes más cercanas a los observados frente a los de escala 0.5°. Las escalas grandes deben tener en cuenta el caudal del río Magdalena por su cercanía con la cuenca del río Prado permitiendo que las series contengan grandes magnitudes que no se asemejan a las subcuencas Cunday y San Pablo.

7.4. EVALUACIÓN DEL DESEMPEÑO DE CADA MIEMBRO DEL ENSAMBLE

Parte de la justificación para realizar el trabajo de grado y premisa del concepto de ensambles señala que en su mayoría el desempeño del ensamble es mejor que cada uno de los modelos o miembros del mismo. Por esta razón y previo a mencionar los resultados del ensamble, se evalúa el desempeño de cada uno de los modelos frente a los registros observados. Se muestran en las Tabla 7-3 y Tabla 7-4 el resultado de la evaluación del desempeño de cada modelo mediante las métricas determinísticas NSE y KGE para las dos escalas temporales.

En la Tabla 7-3 (dividida por su tamaño) se sombrearon de color verde el mejor valor de la métrica para cada cuenca para tenerlo como referencia en la evaluación del desempeño del ensamble. De allí se decide cual es el mejor modelo (MM) para cada métrica, cuenca y escala temporal. Se observa que en la cuenca Cunday los valores de NSE de 0.39 y KGE de 0.45 para el mismo modelo local KerasBrochero, la cuenca San Pablo obtuvo un NSE de 0.35 del modelo local KerasBrochero y KGE de 0.49 con el modelo regional MESH, la cuenca Prado obtuvo valores negativos de NSE con el modelo regional VIC y KGE de 0.30 con el modelo global JRC de escala 0.25°.

Tabla 7-3. Desempeño cada modelo vs los observados escala diaria periodo de calibración

Cuenca	Metrica	CNRS	CSIRO	ECMWF	JRC	KASSEL	METEO	UU
Cunday	NSE	-3945	-4961.5	-5735	-7675	-12372	-3338	-9570
Cunday	KGE	-88.25	-103.66	-99.83	-125.1	-148.52	-81.75	-141.4
San Pablo	NSE	-3110	-4828.9	-4339.1	-5308	-8319.4	-3113	-2481
San Pablo	KGE	-61.43	-78.56	-70.4	-80.86	-98.14	-61.8	-54.82
Prado	NSE	-18.15	-29.2	-31.18	-35.87	-66.17	-16.41	-15.27
Prado	KGE	-2.37	-3.24	-3.6	-3.81	-5.83	-2.2	-1.99

Cuenca	Metrica	GLDAS	KASSEL025	JRC025	ECMW025	MESH	VIC	K.DEVOS	K.BROCHERO	SWATin-situ	SWATdistri
Cunday	NSE	-0.28	-43.98	-7933.7	-17.69	-4.2	0	0.16	0.39	-6.34	-0.63
Cunday	KGE	-0.52	-7.13	-132.57	-4.3	-1.2	-0.08	0.13	0.45	-0.93	0.23
San Pablo	NSE	-0.42	-0.16	-1.15	-0.08	-0.16	-0.02	0.14	0.35	-5.85	-0.66
San Pablo	KGE	-0.37	0.33	-0.25	0.19	0.49	-0.19	0.09	0.43	-0.82	0.31
Prado	NSE	-5.72	-83.2	-0.37	-0.71	-1.19	-0.15	-0.25	-0.16	-6.77	-2.82
Prado	KGE	-0.74	-6.56	0.30	0.21	-0.34	-0.02	-0.87	0.1	-0.92	-0.19

Fuente: Elaboración propia

A nivel mensual, ver Tabla 7-4 (dividida por su tamaño) se sombrearon de color salmón el mejor valor de la métrica para cada cuenca para tenerlo como referencia en la evaluación del desempeño del ensamble. La Tabla 7-4 muestra en primera instancia un mejor desempeño de los modelos locales, los valores de las métricas son superiores. En las cuencas Cunday y San Pablo fue el modelo SWAT de precipitación distribuida el que tuvo valores de NSE de 0.56 y KGE 0.74, y NSE de 0.73 y un KGE de 0.85, respectivamente. La última cuenca, Prado, tuvo al modelo KerasBrochero como su mejor opción. Con este modelo se obtuvo un NSE de 0.49 y KGE de 0.6.

Tabla 7-4. Desempeño de cada modelo vs los observados escala mensual periodo de calibración

Cuenca	Metrica	CNRS	CSIRO	ECMWF	JRC	KASSEL	METEO	UU
Cunday	NSE	-16700	-21762	-18626	-32370	-38048	-14854	-33758
Cunday	KGE	-107	-118.69	-113.22	-147.9	-159.36	-101.3	-142.1
San Pablo	NSE	-12445	-19907	-12545	-20758	-21989	-13239	-7716
San Pablo	KGE	-81.35	-96.09	-82.74	-104.2	-106.58	-83.77	-55.53
Prado	NSE	-286	-465.34	-293.17	-518.9	-559.19	-285.4	-170.3
Prado	KGE	-10.62	-12.34	-10.9	-14.33	-14.73	-10.66	-6.26

Cuenca	Metrica	GLDAS	KASSEL025	JRC025	ECMW025	MESH	VIC	K.DEVOS	K.BROCHERO	SWATin-situ	SWATdistri
Cunday	NSE	-15.23	-100.28	-34205	-49.04	-319.9	-341	0.45	0.35	0.15	0.56
Cunday	KGE	-2.15	-6.91	-147.15	-4.47	-14.3	-13.4	0.52	0.42	0.58	0.74
San Pablo	NSE	-100.78	0.51	-4.31	0.11	-385.7	-1304	0.42	0.33	-0.09	0.73
San Pablo	KGE	-6.34	0.62	-0.44	0.43	-13.83	-21.2	0.49	0.39	0.44	0.85
Prado	NSE	-8765.9	-138.51	-206.72	-109.07	-2.01	-1438	0.18	0.49	0.2	-0.92
Prado	KGE	-6	-6.1	-7.53	-5.46	-0.01	-19.7	0.2	0.6	0.56	0.26

Fuente: Elaboración propia

El desempeño de los modelos globales de escala 0.5° fue muy bajo. Se considera la cercanía con el río Magdalena como la causa de las grandes magnitudes de estos modelos ya que la

celda de 0.5° seguramente abarca el cauce de este río. A pesar de esta situación, los miembros globales continuaron participando de todos los posibles ensambles dado que el concepto de los ensambles es aprovechar ventajas y desventajas de todos los modelos, además no generaba mayor costo computacional incluirlos dentro del estudio (características del computador de desarrollo en el ítem 7.1.3).

7.5. ANÁLISIS DE LA CANTIDAD DE MIEMBROS FRENTE AL DESEMPEÑO DE LOS 50 MEJORES ENSAMBLES PROMEDIO SEGÚN MÉTRICA KGE Y CRPS

Para cada cuenca y escala de tiempo se reprodujeron 131.054 ensambles promedio (ver Tabla 5-1) que fueron evaluados con las métricas NSE, KGE y CRPS. La Figura 7-15 relaciona los 50 mejores ensambles promedio para las métricas KGE y CRPS para las tres cuencas y ambas escalas temporales. Buscando identificar características de los mejores ensambles con respecto al número de miembros que lo componen. Los mejores valores de KGE y NSE se aproximan a uno y los mejores valores de CRPS se aproximan a cero.

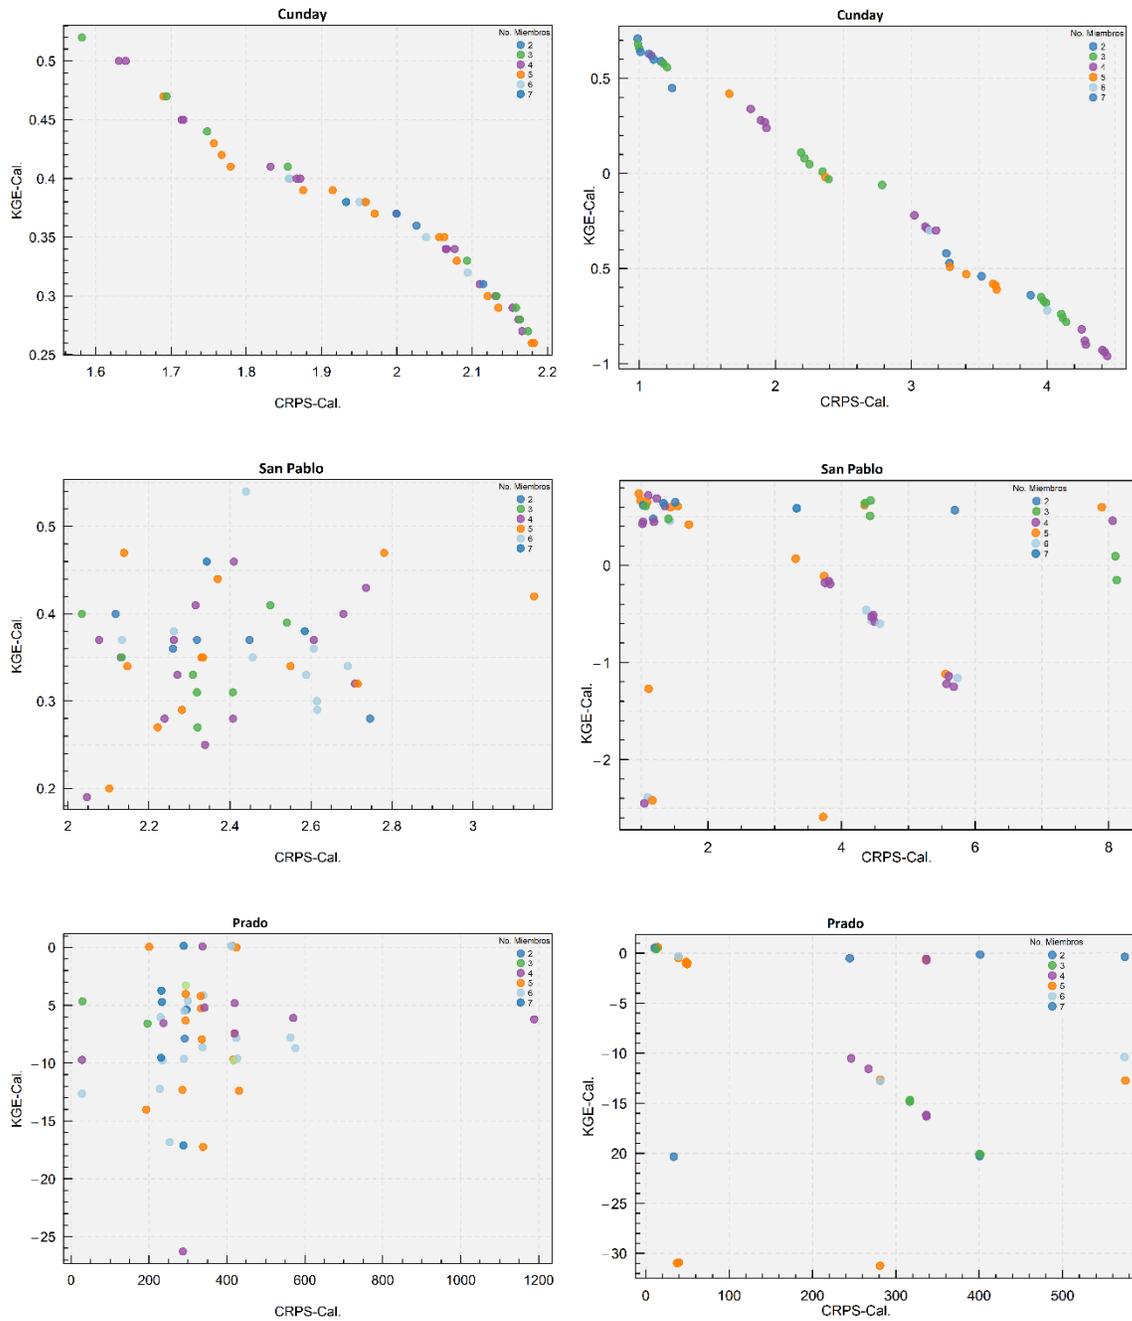
Estas características fueron: primero, el número total de modelos o miembros que componen los mejores ensambles no superaron los 7 miembros y la segunda, no siempre la misma cantidad de miembros generó los mejores desempeños en el ensamble, es decir, los mejores valores no siempre fueron para una misma cantidad de miembros.

¿Qué tipo de miembros participan dentro de los mejores 50 ensambles promedios? Corresponden a los modelos locales mayoritariamente, a los regionales y en algunas ocasiones a los modelos globales de escala 0.25°.

Figura 7-15. Cantidad de miembros y comportamiento de las métricas KGE vs CRPS en 50 ME promedio. Arriba Cunday, centro San Pablo y Abajo Prado.

Diarios

Mensuales



Fuente: Elaboración propia

7.6. DESEMPEÑO DE LOS ENSAMBLES PROMEDIO SEGÚN EL NÚMERO DE MIEMBROS

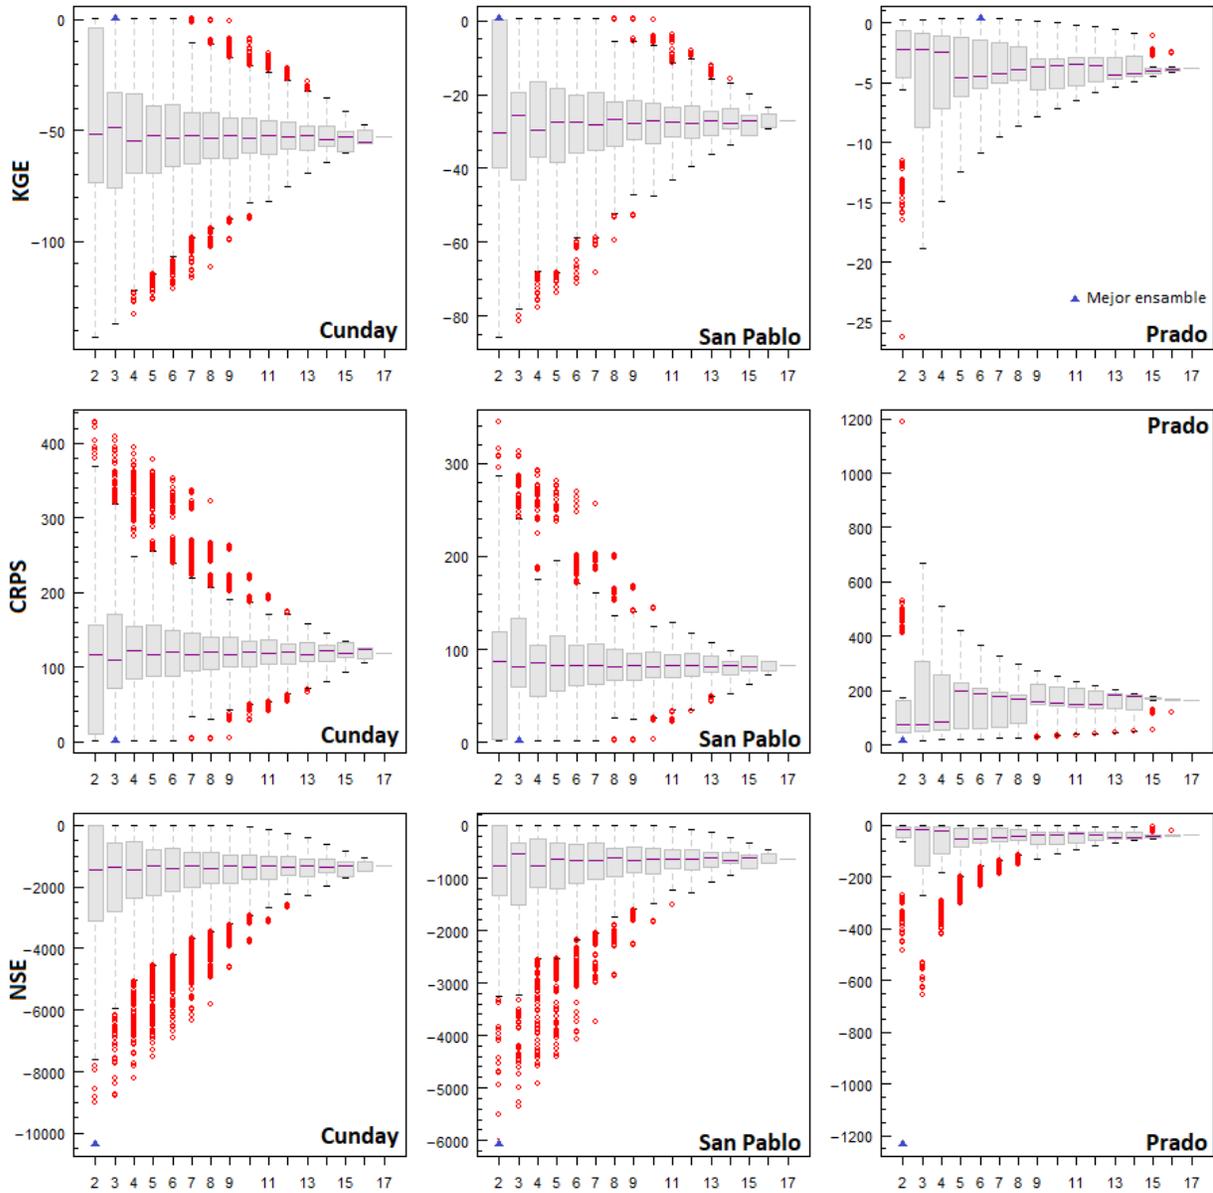
El desempeño aquí evaluado corresponde al de los 131.054 ensambles promedio que están compuestos de entre 2 y 17 miembros. Para comprender mejor cómo se comporta el desempeño de los ensambles según la cantidad de miembros que lo conforman se construyeron las Figura 7-16 y Figura 7-17. Cabe recordar que el desempeño es evaluado con las métricas KGE, NSE y CRPS en cada combinación para cada cuenca y escala temporal. Las figuras muestran el diagrama de cajas con los valores de las métricas de desempeño para cada cantidad de miembros posibles y se indica el mejor ensamble promedio ME con un triángulo pequeño de color azul.

Sin importar la métrica de desempeño, la cuenca y la escala temporal se observó una reducción de la varianza de los valores del desempeño a medida que aumenta la cantidad de miembros. Además, sin importar que tipos de miembros utilice se presenta la reducción de la variabilidad de los valores de desempeño.

La primera Figura 7-16 muestra en las cuencas Cunday y San Pablo que con los ensambles de dos miembros se pueden obtener los mejores desempeños, pero ambiguamente, también con dos miembros es muy factible estimar malos desempeños debido a la gran cantidad posibles combinaciones de dos modelos que tienen mal desempeño. Esto también sucede en la cuenca Prado con 3 y 4 miembros.

El valor medio de todos los desempeños en ambas métricas para las cuencas Cunday y San Pablo es aproximadamente estable y no se modifica mucho mediante el aumento de miembros en el ensamble. Por ejemplo, para los ensambles de 12 miembros, sin importar cuales de ellos son, el valor de desempeño fue similar.

Figura 7-16. Desempeño de todos los ensambles promedio según KGE (arriba), CRPS (centro) y NSE (abajo) frente al número de miembros en las cuencas Cunday (Izq.), cuenca San Pablo (centro) y cuenca Prado (Der.). Escala diaria

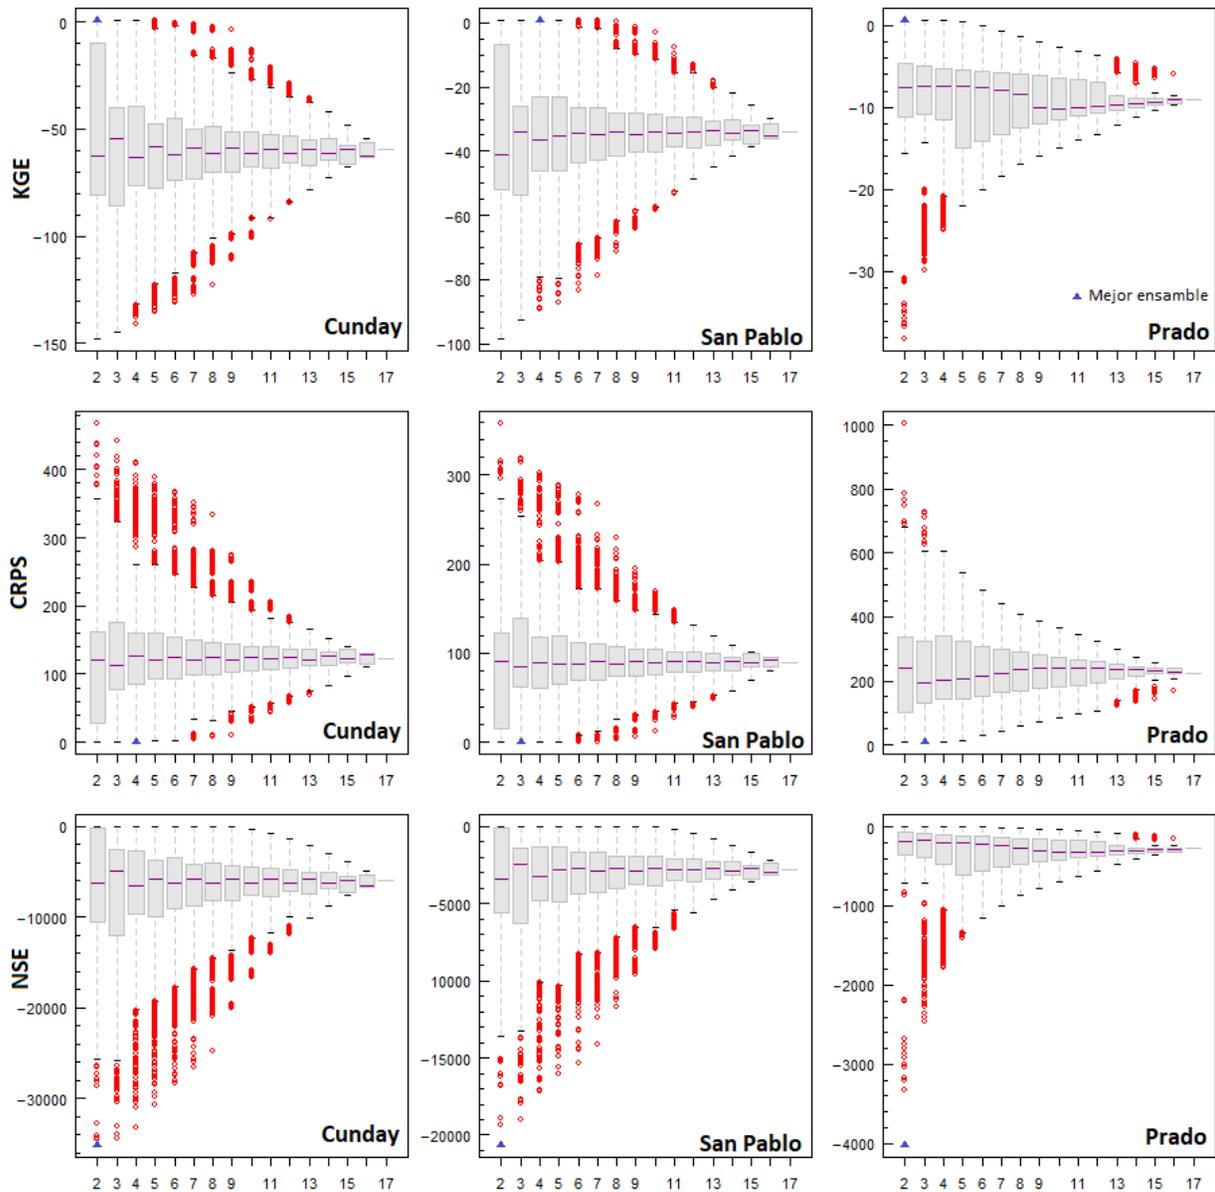


Fuente: Elaboración propia

A escala mensual en las 3 cuencas, los valores de desempeño de los ensambles según la métrica CRPS son más estables que sus similares para la métrica KGE donde la mediana de los diagramas oscila más.

En las cuencas Cunday y San Pablo, como en la escala diaria, los mejores ensambles ME presentan cuando se juntan dos miembros. Sin embargo, debido a la variabilidad de los datos en el diagrama se pueden también presentar los peores desempeños.

Figura 7-17. Desempeño de todos los ensambles promedio según KGE (arriba), CRPS (centro) y NSE (abajo) frente al número de miembros en las cuencas Cunday (Izq.), cuenca San Pablo (centro) y cuenca Prado (Der.). Escala Mensual

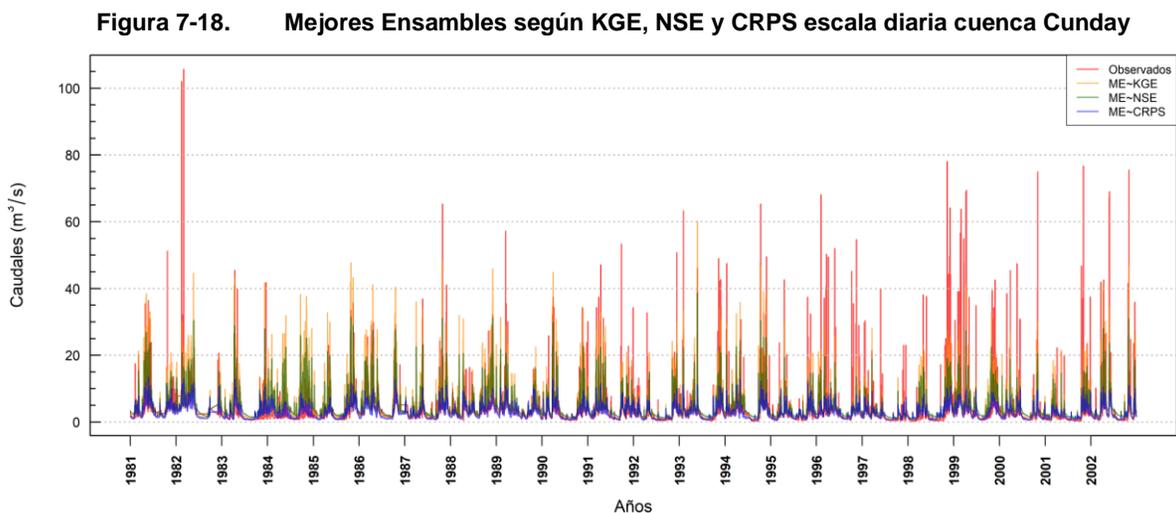


Fuente: Elaboración propia

7.7. COMPORTAMIENTO DE LOS MEJORES ENSAMBLES PROMEDIO

Anteriormente se mostraron los desempeños de todos los ensambles promedio con respecto al número de miembros, ahora se muestra el único mejor ensamble promedio (ME) por cada métrica y cuenca con el interés de ver las series de caudales no solo desde el valor de una métrica, sino desde su comportamiento. La comparación de la evaluación de los ME mediante las métricas es mostrada en el apartado 7.9 ¿MEJORA LA ESTIMACIÓN DE LOS CAUDALES CON EL MEJOR ENSAMBLE?

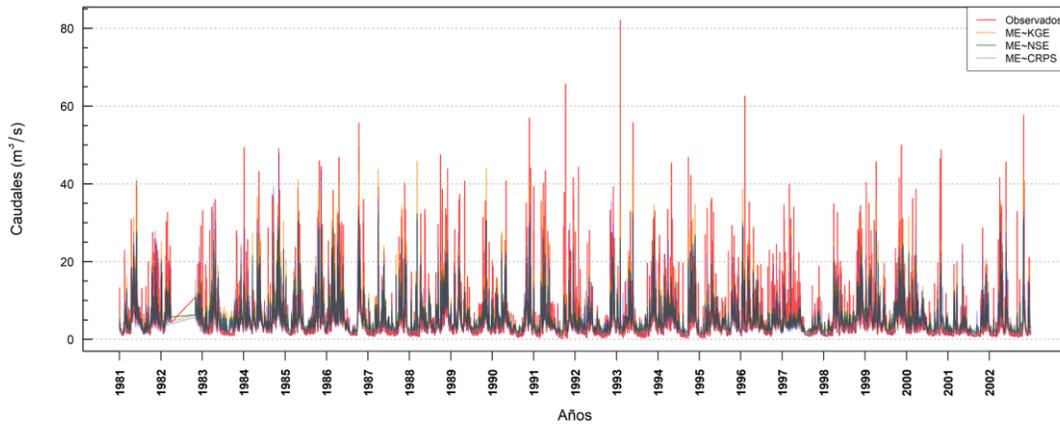
La cuenca Cunday presenta un ME~KGE de mayores magnitudes que el ME~NSE y éste mayores magnitudes frente a ME~CRPS, pero todos siguen una tendencia de los valores medios con su periodicidad anual. Los valores extremos máximos no fueron simulados con exactitud (ver Figura 7-18). Todo este comportamiento debe ser una consecuencia de tener un promedio de los modelos.



Fuente: Elaboración propia

Los tres ME de la cuenca San Pablo simulan la periodicidad de la serie observada de buena manera, pero los ME~NSE y ME~CRPS logran simular mejor los caudales bajos en contraste con el ME~KGE que logra simular más los valores máximos sin dejar de ver que los caudales extremos máximos no logran ser reproducidos en su totalidad (ver Figura 7-19). La no simulación de los valores máximos puede deberse a la conformación promedio de los ensambles.

Figura 7-19. Mejores Ensamblas según KGE, NSE y CRPS escala diaria cuenca San Pablo



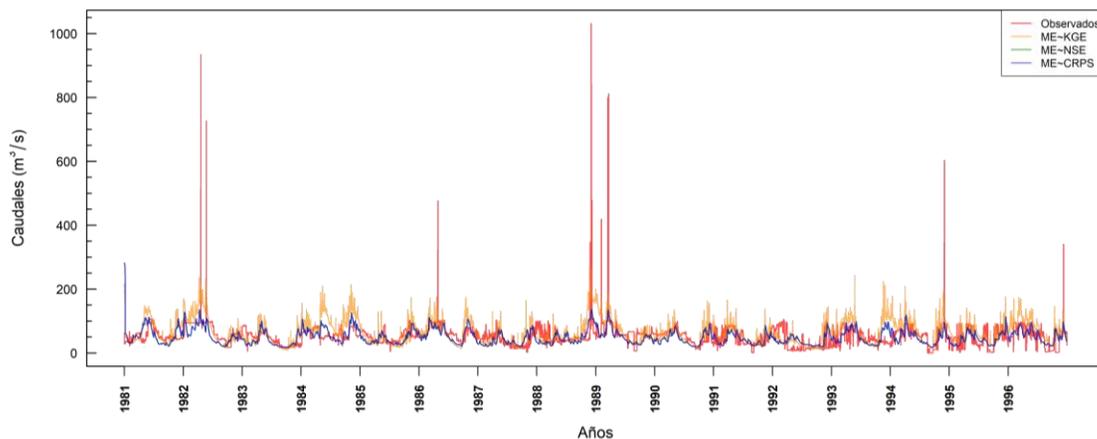
Fuente: Elaboración propia

Los ensambles promedio de la cuenca Prado muestran que el comportamiento del ME~CRPS y ME~NSE son totalmente similares porque la misma combinación de los modelos resultó en el mejor valor de esas métricas mientras que el ME~KGE tiene un comportamiento diferente y de mayores magnitudes (ver Figura 7-20).

Los ME no ajustan a los valores extremos máximos de la serie porque son resultantes de un promedio de modelos que tampoco ajustaron perfectamente a estas condiciones extremas que no solo obedecen a la hidrología sino a la operación del embalse Prado. Las condiciones promedio también hace que los valores mínimos no sean bien reflejados por los ME.

Las series se asemejan en su comportamiento oscilatorio anual, es decir, los valores medios son simulados de buena manera.

Figura 7-20. Mejores Ensamblas según KGE, NSE y CRPS escala diaria cuenca Prado



Fuente: Elaboración propia

7.8. PARTICIPACIÓN DE TODOS LOS MODELOS O MIEMBROS FRENTE AL MEJOR ENSAMBLE PROMEDIO SEGÚN CRPS, NSE Y KGE.

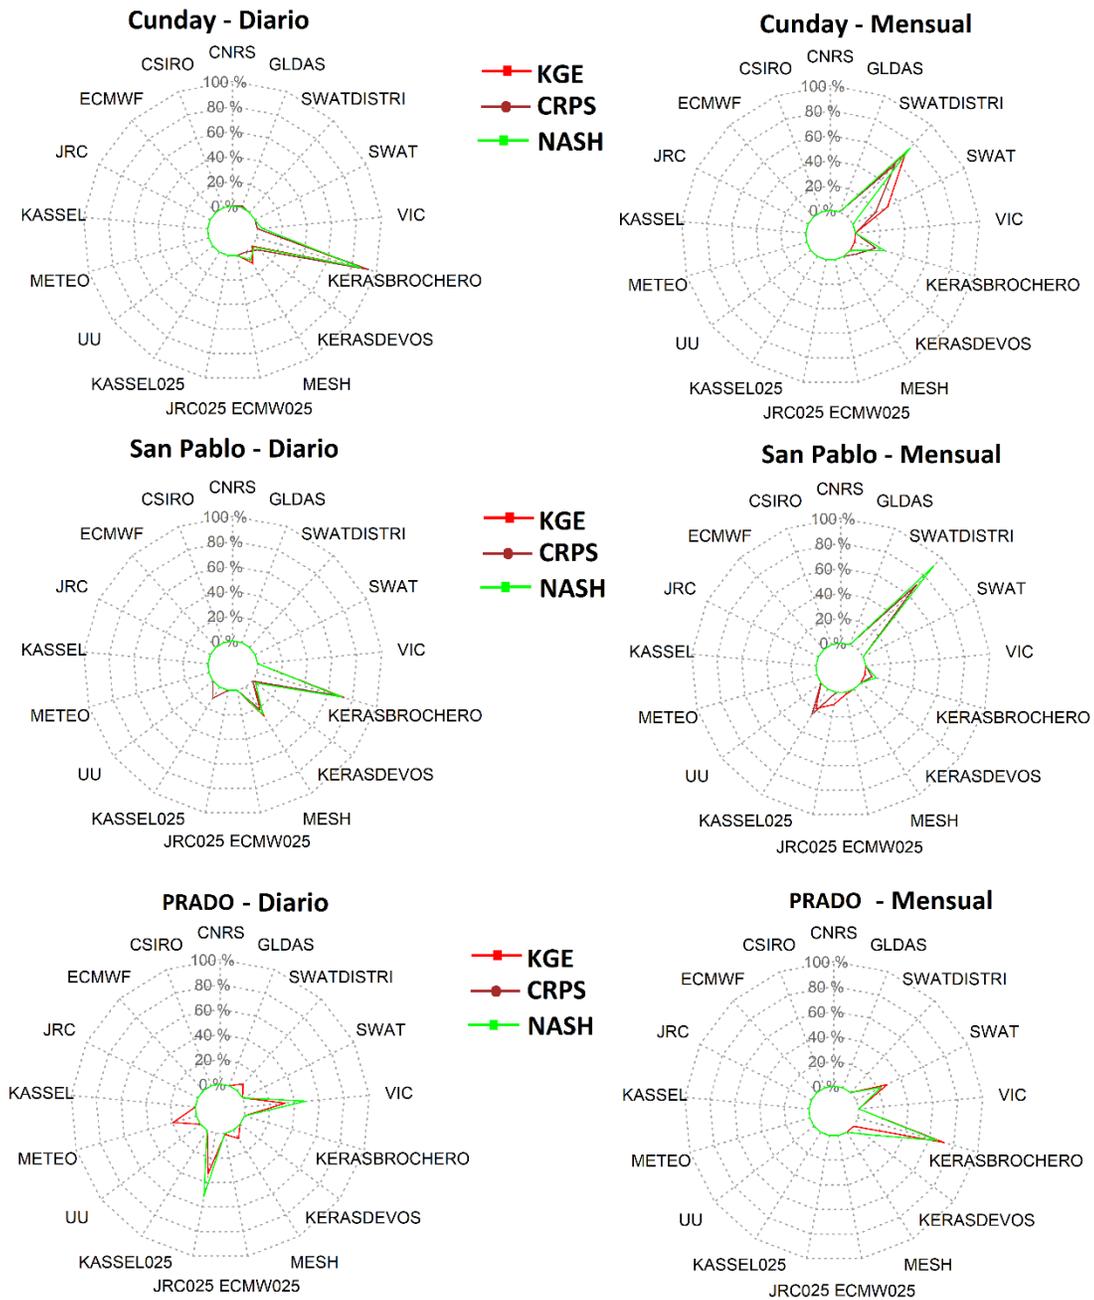
Anteriormente se había descrito el comportamiento de los mejores ensambles promedio (ME) y el número de miembros que los constituyen, ahora, mediante el método BMA se identificó cuales miembros o modelos son los que participan en cada uno de los ensambles promedio en ambas escalas temporales (ver Figura 7-21) y cuanto peso o participación tienen esos modelos en la constitución de cada ME a escala diaria (ver Figura 7-22) y escala mensual (Figura 7-23).

Mediante la gráfica de radar, Figura 7-21, para las dos escalas temporales se muestra cuales modelos son los que participan en cada mejor ensamble, ME~KGE color rojo, ME~NSE color marrón y ME~CRPS color verde. En la gráfica se observa que predominantemente son más los miembros que no participan en los ensambles. Ejemplo de ello son los modelos globales que provienen de una escala espacial 0.5° , los cuales no están dando ningún peso.

Los otros modelos globales de escala 0.25° no participan en la cuenca Cunday, pero en las cuencas San Pablo y Prado ya tienen alguna participación minoritaria. Los modelos regionales sí participan en la cuenca San Pablo y en Prado a nivel diario. Y en todos los casos al menos un modelo local hace parte de los ensambles sin importar la escala temporal y la cuenca.

En una misma cuenca para las dos escalas temporales no es el mismo modelo el que más participación peso tiene dentro del ensamble. Por ejemplo, a escala diaria el ensamble en la subcuenca Cunday tiene una participación importante del modelo KerasBrochero frente a la importante participación del modelo SWATdistri en la misma cuenca, pero a escala mensual. En esta subcuenca, el modelo KerasBrochero también participa a escala mensual como miembro del ensamble, pero es superior el aporte de SWATdistri posiblemente por el tipo de modelo y origen de este. Otra razón para la diferencia de modelos que conforman los ensambles para la subcuenca Cunday sería, que el modelo KerasBrochero a escala diaria al manejar la variabilidad propia de la serie mediante variables rezagadas, particularmente el caudal logra tener un muy buen desempeño que otros modelos no lograron representar.

Figura 7-21. Esquema radial de participación de los modelos dentro del mejor ensemble

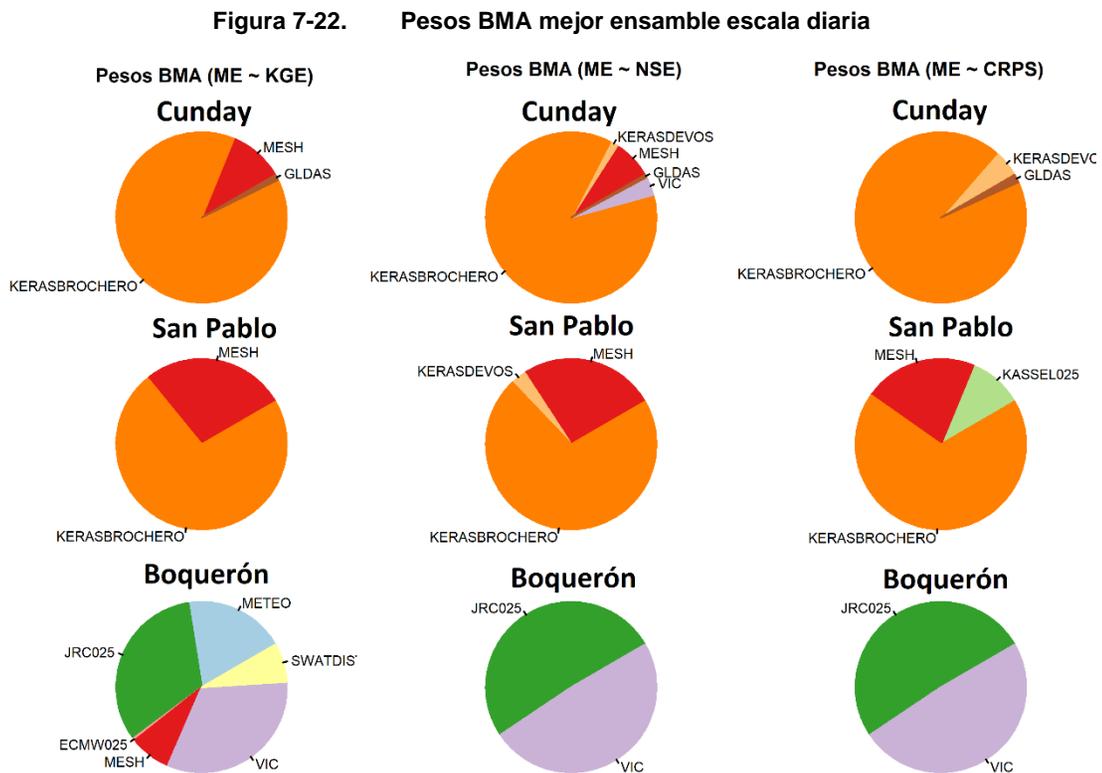


Fuente: Elaboración propia

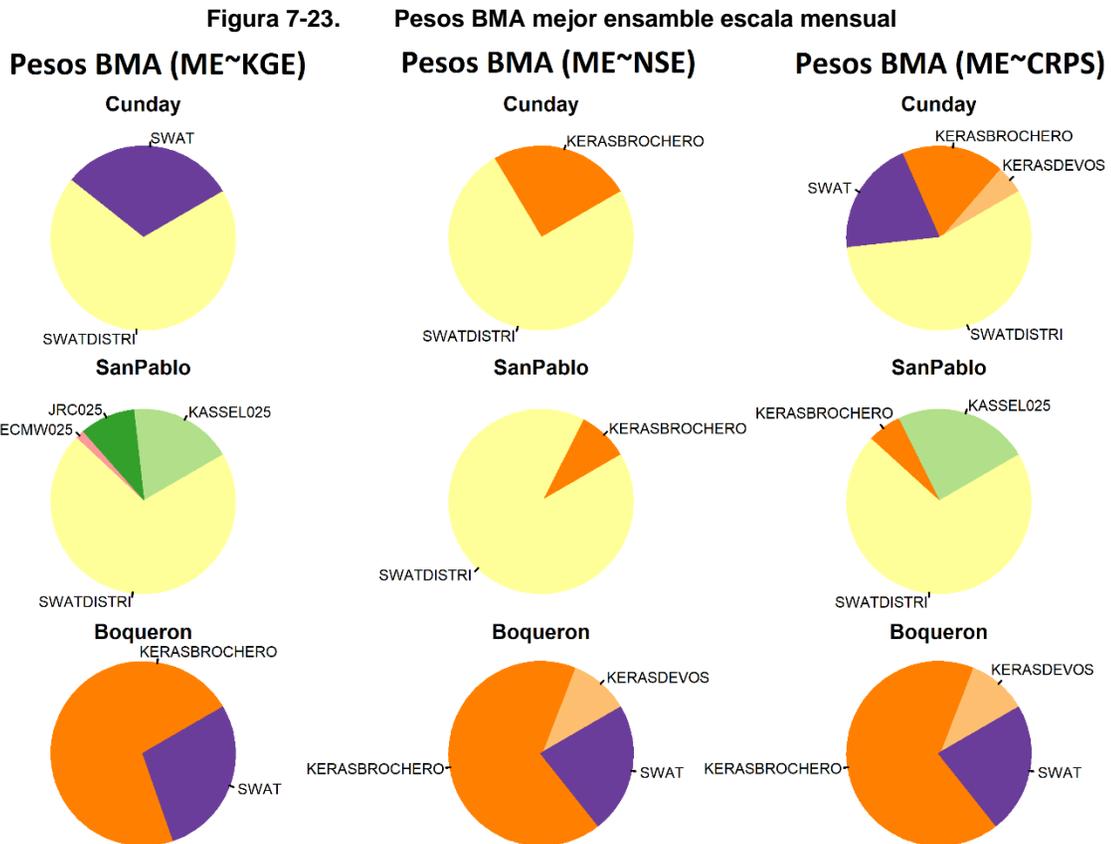
A escala diaria, el modelo KerasBrochero en las cuencas de Cunday y San Pablo tiene una participación predominante como miembro del ensemble según las tres métricas de desempeño, más no tiene participación en la cuenca Prado, Figura 7-22. De alguna manera el proceso de autoaprendizaje está carente de información que le permita acertar los caudales de esta cuenca. Se puede pensar que la causa sería por el proceso de generación de energía

y el llenado del embalse que no ha sido incluido en este modelo. Sin embargo, a escala mensual, ver Figura 7-23, el modelo KerasBrochero tuvo buen desempeño en la misma cuenca.

Los modelos globales, como es el caso de JRC025 a escala diaria y KASSEL025 logran ser parte de un ensamble a pesar de que las magnitudes, que, juzgando a priori, eran más altas que los observados.



Fuente: Elaboración propia



Fuente: Elaboración propia

7.9. ¿MEJORA LA ESTIMACIÓN DE LOS CAUDALES CON EL MEJOR ENSAMBLE?

La estrategia de mejorar la estimación de los caudales mediante el profundo esfuerzo y dedicación al mejoramiento de un modelo hidrológico no fue considerada dentro del objeto del trabajo de grado. En cambio, se buscó que la utilización de múltiples modelos mediante el concepto de ensamble hidrológico pueda contribuir a la mejora de la estimación de los caudales en la cuenca de estudio.

Antes de referenciar cifras del desempeño de los ensambles es muy importante señalar que la pregunta del subtítulo es respondida para las condiciones particulares del trabajo de grado en la cuenca Prado en dirección con el tercer objetivo que es la evaluación del ensamble construido. Es decir, aún la respuesta no es afirmativa para todos los ensambles hidrológicos ni mucho menos para todos los ensambles hidrológicos aplicados a la cuenca del río Prado.

Las comparaciones evidenciadas en el periodo de calibración (Figura 7-24) y validación (Figura 7-25) a escala diaria y periodo de calibración (Figura 7-26) y validación (Figura 7-27) a escala

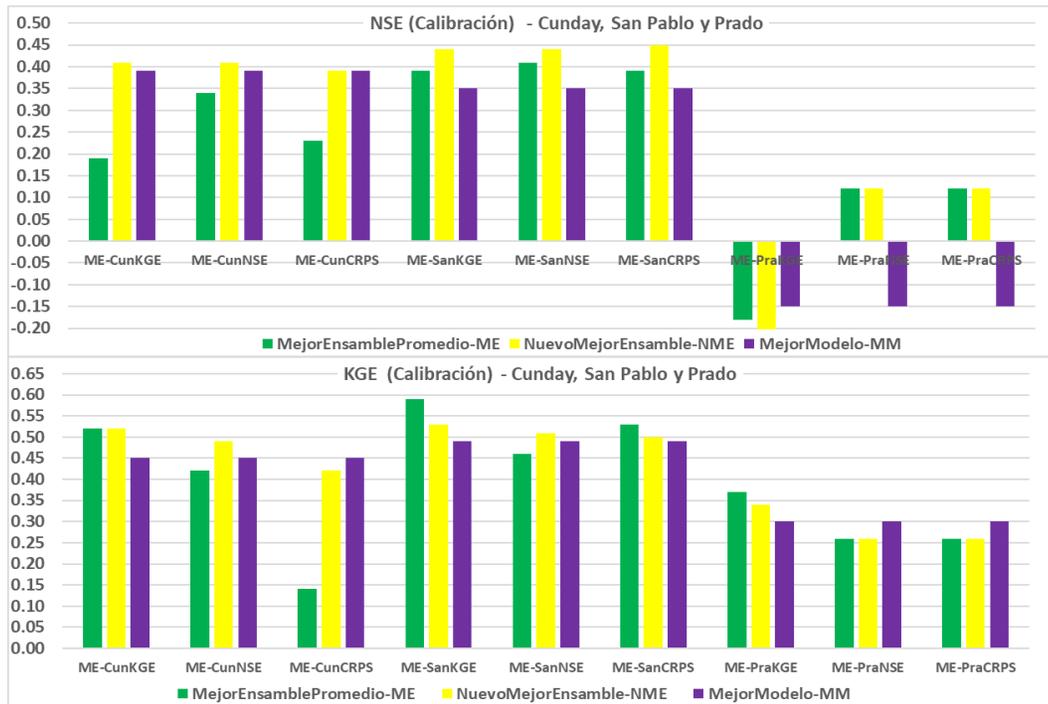
mensual muestran una comparación triple en cada métrica y en cada cuenca. (i) el desempeño del mejor modelo entre los 17 utilizados de color morado, (ii) el desempeño del mejor ensamble promedio (ME) de color verde y (iii) el desempeño del nuevo mejor ensamble (NME) de color amarillo para el periodo de calibración del ensamble. El NME corresponde a la generación de una nueva serie de caudales considerando el peso del modelo dentro del ensamble según fue estimado mediante BMA, es decir, NME es un promedio ponderado.

En el periodo de calibración para la evaluación de la métrica NSE, en la mayoría de los casos el NME, que incluye los pesos, mostró un mejor desempeño frente al MM y frente al ME. Situación que no se evidencia tan clara para la evaluación de KGE. Allí, el NME no tuvo mejor desempeño que el ME e inclusive, ambos tuvieron menor desempeño que el MM para tres casos: ME-CunCRPS, ME-PraNSE y ME-PraCRPS. Esto puede deberse a que la métrica KGE no castiga fuertemente la incapacidad de simular los valores extremos. Es decir, el MM para estos casos fue KerasBrochero, el cual sigue bastante el comportamiento medio de los observados y no tanto los valores extremos. Por esta razón, el NME ensamble que sí incluye un poco más la variabilidad de los observados frente al modelo KerasBrochero, no supera a este último en su desempeño.

En el periodo de calibración a escala diaria para la evaluación utilizando NSE y KGE, ver Figura 7-25, el NME logró mejores desempeños frente a ME y MM hasta en una décima excepto para el ensamble de la cuenca Prado. En este periodo, en ensamble promedio ME tuvo mejor desempeño que el MM. A escala mensual, los NME, también, tienen mejor desempeño que los ME y MM. En particular en este escala mensual y periodo de validación se registran mejor desempeño del MM frente a los ensambles promedio ME.

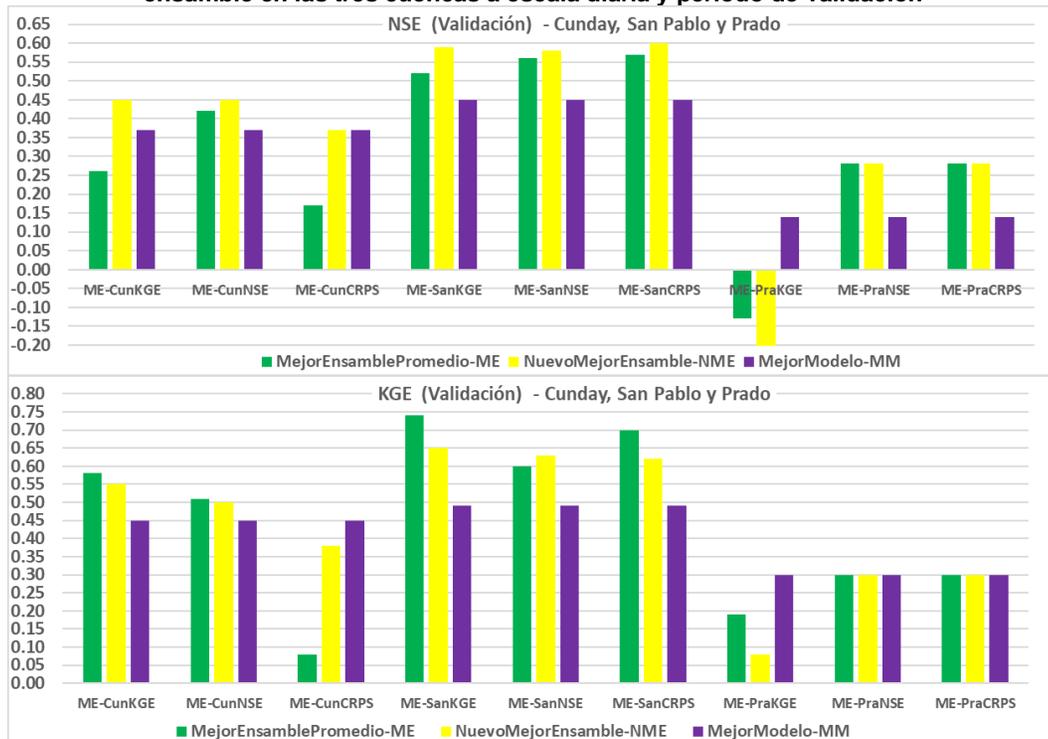
En Figura 7-26 se observa que el ME de pesos para ambas métricas en su mayoría tuvo mejor desempeño que el MM. Similar a la escala diaria, la evaluación KGE para la cuenca Prado no presentó mejoría con los dos ME.

Figura 7-24. Evaluación del desempeño del mejor modelo, mejor ensamble promedio y nuevo mejor ensamble en las tres cuencas a escala diaria y periodo de calibración



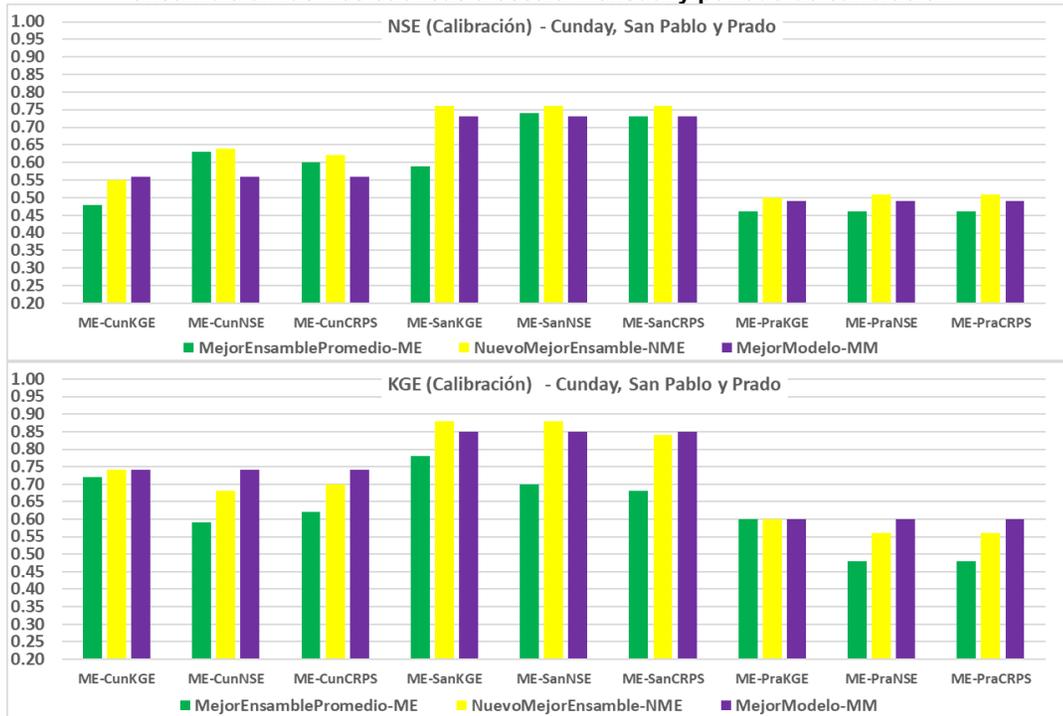
Fuente: Elaboración propia

Figura 7-25. Evaluación del desempeño del mejor modelo, mejor ensamble promedio y nuevo mejor ensamble en las tres cuencas a escala diaria y periodo de validación



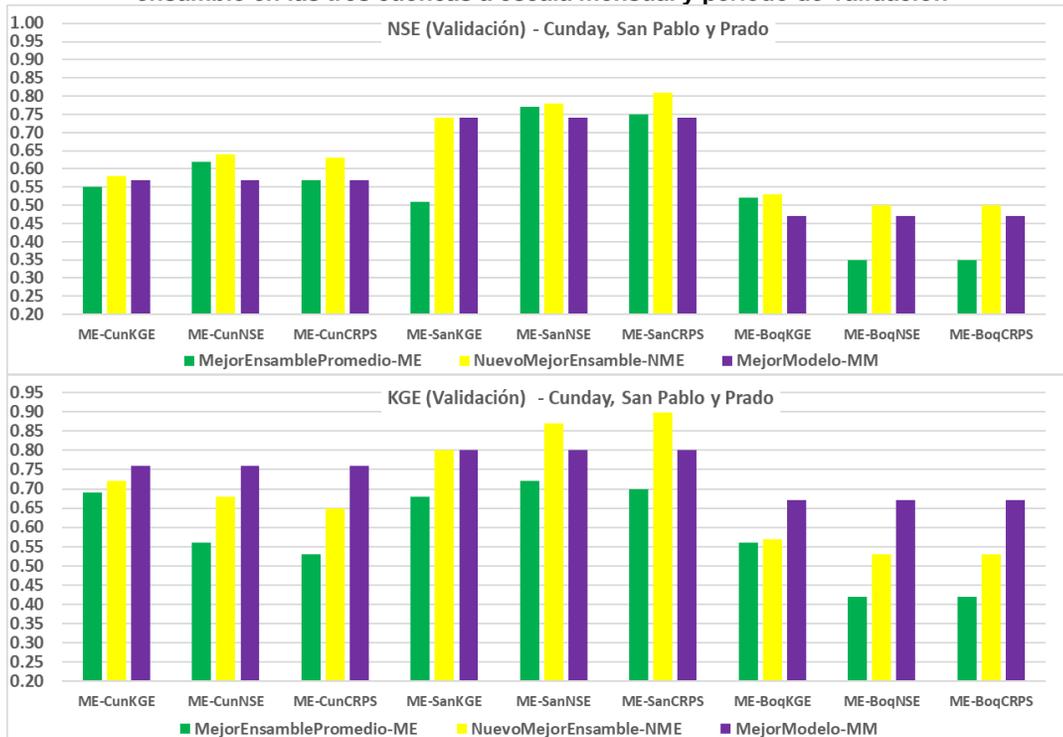
Fuente: Elaboración propia

Figura 7-26. Evaluación del desempeño del mejor modelo, mejor ensamble promedio y nuevo mejor ensamble en las tres cuencas a escala mensual y periodo de calibración



Fuente: Elaboración propia

Figura 7-27. Evaluación del desempeño del mejor modelo, mejor ensamble promedio y nuevo mejor ensamble en las tres cuencas a escala mensual y periodo de validación

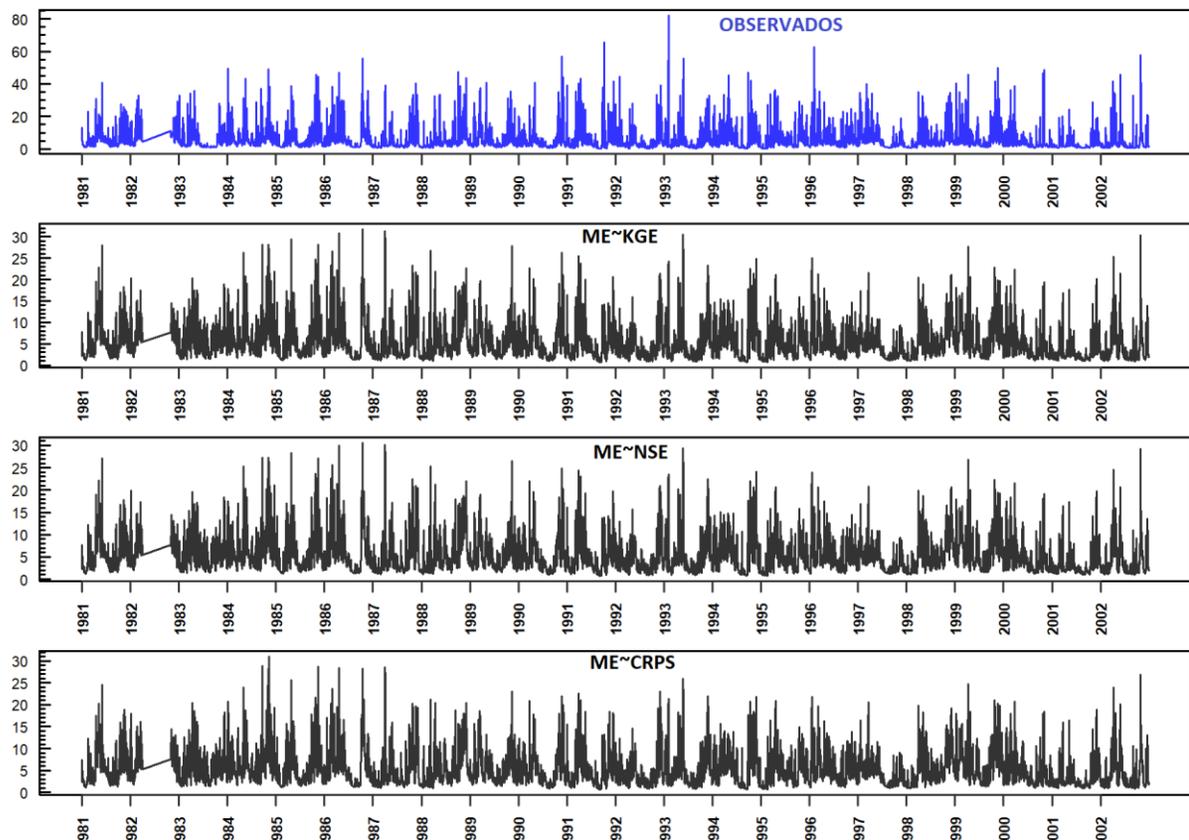


Fuente: Elaboración propia

Aparte de evaluar los ensambles desde las métricas de desempeño, a continuación, se muestran las series de cada NME~KGE, NME~NSE y NME~CRPS en el periodo de calibración de la cuenca San Pablo a escala diaria. Las series diarias de las otras cuencas y las series mensuales son presentadas en el ANEXO 3.

La Figura 7-28 muestra que los NME en las tres métricas simulan de buena manera las tendencias periódicas de la serie de observados, también los valores medios son bien representados en sus magnitudes, pero los valores máximos de los tres ensambles no se aproximan a los más extremos. En San Pablo se han presentado eventos máximos superiores a 30 m³/s y ese es el máximo caudal de los tres ensambles.

Figura 7-28. Observados y mejor ensamble (NME~KGE, NME~NSE y NME~CRPS) Cuenca San Pablo escala diaria periodo 1981-2002 de calibración.



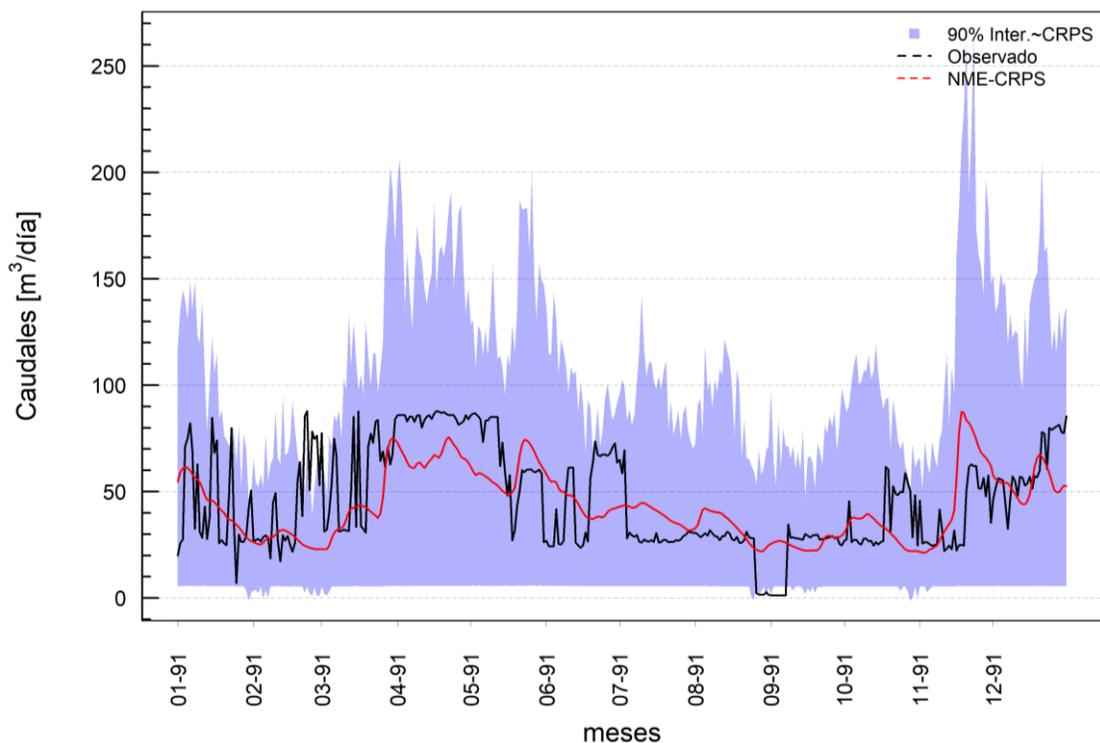
Fuente: Elaboración propia

7.10. ANÁLISIS Y EVALUACIÓN DE LA INCERTIDUMBRE DEL ENSAMBLE

El análisis sobre la construcción del ensamble hidrológico no solo está encaminado a la estimación de los caudales y a la evaluación del desempeño, sino también a la estimación de la incertidumbre. Las siguientes figuras muestran algunos resultados puntuales, aunque la estimación se hizo para toda la serie en las tres cuencas en ambas escalas temporales y para cada uno de los NME. Estos resultados generales, serán mostrados posteriormente a los casos particulares mediante una tabla resumen.

En la Figura 7-29 se muestra el caso particular de la franja de incertidumbre del NME~CRPS en su escala diaria para la cuenca Prado 3 en el año 1991 en donde se observa que la franja gris generada a partir de los valores simulados (línea roja) puede alcanzar el doble de magnitud de los valores observados (línea negra), es decir que casi todos los valores observados del año 1991 están incluidos dentro de la envolvente o franja de incertidumbre del ensamble. Por lo tanto, la incertidumbre del ensamble abarca la mayoría de los valores observados.

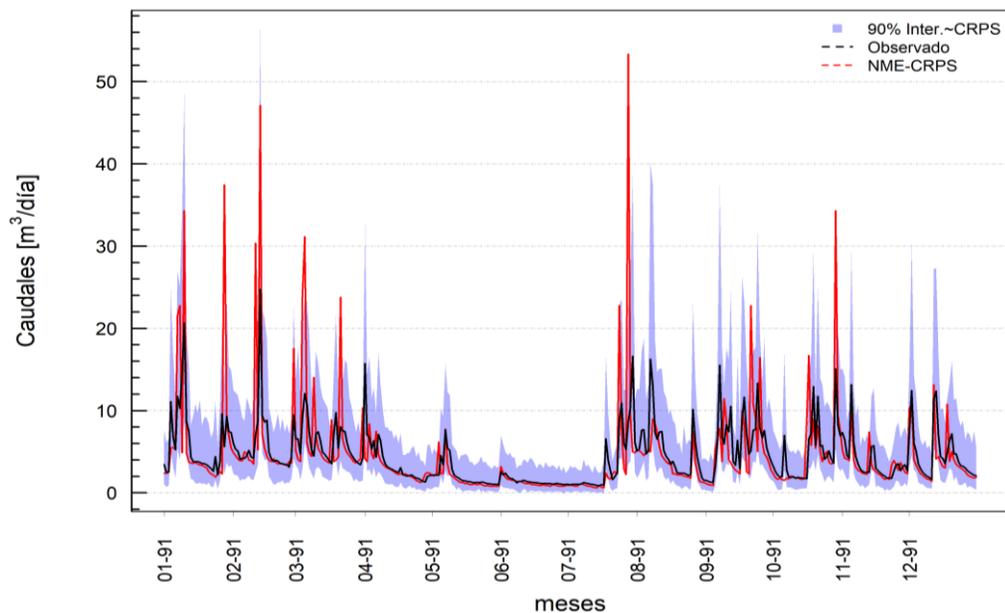
Figura 7-29. Franja de incertidumbre del NME~CRPS cuenca Prado año 1991.



Fuente: Elaboración propia

En la Figura 7-30 se presenta la cuenca Cunday en el mismo año 1991 con su franja de incertidumbre para el NME~CRPS. Contrastando la cuenca Prado con la subcuenca Cunday, la incertidumbre es mucho mayor en Prado, y no solo por la magnitud media de los caudales, sino por el resultado de los miembros que conformaron este ensamble. En este ensamble predomina la participación del modelo KerasBrochero alcanzando cercanía al 80% y el restante porcentaje está dado por los modelos KerasDeVos y GLDAS. La franja de incertidumbre se hace menor debido a que está creada principalmente con el modelo, KerasBrochero, el cual tiene un buen desempeño.

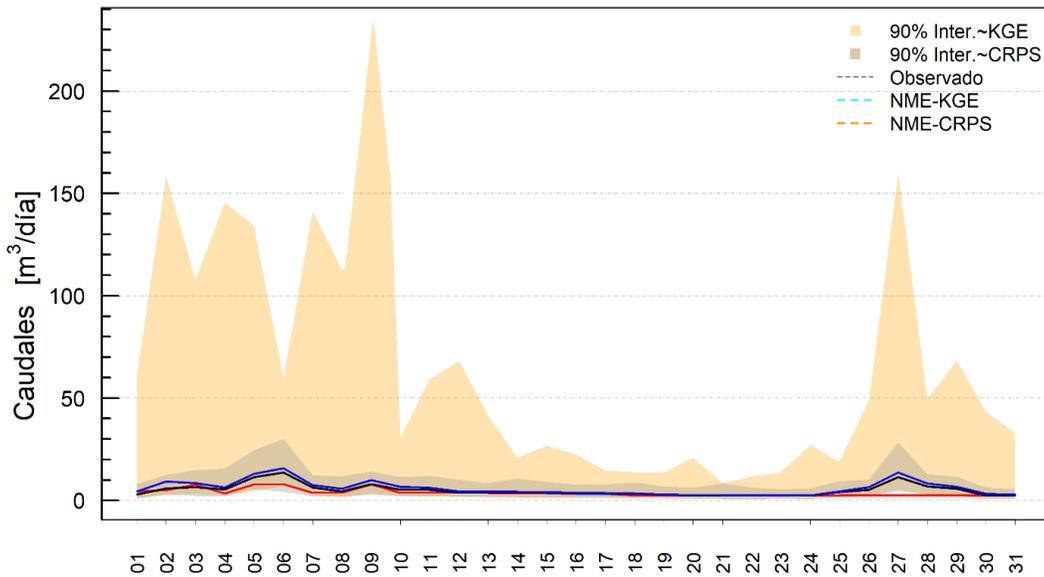
Figura 7-30. Franja de incertidumbre cuenca Cunday del NME~CRPS año 1991



Fuente: Elaboración propia

Ahora se muestra el rango de incertidumbre del mes de mayo de 1991 para los dos NME ~KGE y NME~CRPS en donde se observa que la franja del NME~KGE es mucho mayor a pesar de que las series de caudales de los NME son similares en sus magnitudes. A pesar de que no se muestra toda la serie, es algo particular de las franjas para las dos métricas determinísticas, son superiores a las de la métrica probabilística. Esto se debe a un miembro que hace parte del NME~KGE y no hace parte del NME~CRPS que es MESH. Con este modelo se puede obtener caudales hasta un orden de magnitud superior a caudales observados estableciendo una mayor franja de incertidumbre.

Figura 7-31. Franja de incertidumbre mayo de 1991 cuenca Cunday escala diaria



Fuente: Elaboración propia

Las incertidumbres gráficamente se vieron en las anteriores figuras, pero mediante tres criterios fueron evaluadas numéricamente. En la Tabla 7-5 se muestran los resultados para la escala diaria para el periodo de calibración y validación de los tres criterios para cada uno de los tres NME. En la Tabla 7-6 se muestran los resultados a escala mensual.

Cabe recordar la definición de los tres criterios. CR (relación de contenidos) es el porcentaje de datos observados que se ubican dentro del rango o límite de las predicciones. ABW: promedio del ancho de la franja y ADA: promedio de la ampliación de la desviación. Los resultados en los criterios son mejores cuando CR tiene mayor porcentaje de los observados, ancho promedio de la franja ABW es bajo y la ampliación de la desviación ADA también es baja.

Respecto al criterio ABW, para ambas escalas temporales se observan predominantemente menores valores en el NME~CRPS tanto en calibración como en validación con algunas excepciones como lo son San Pablo en NME~NSE a escala diaria y Cunday en NME~KGE a escala mensual. Más, sin embargo, el porcentaje de datos observados dentro de la franja CR es mayor para NME~CRPS.

Similar comportamiento tiene el promedio de ampliación de la desviación ADA cuando sus menores valores se registran para el NME~CRPS con algunas excepciones.

Ahora bien, con el ánimo de comparar la incertidumbre entre periodos de calibración y validación cabe resaltar que no es totalmente claro que la incertidumbre se reduzca para el periodo de validación dado que en ciertos casos cuando CR aumenta también se incrementa el ABW. De esta manera, el incremento del porcentaje de datos dentro de la franja pareciera un buen indicador, pero se debe a la ampliación de la franja de incertidumbre, lo cual no es ideal.

Tabla 7-5. Resultado evaluación de la incertidumbre por métricas en las tres cuencas para los tres nuevos mejores ensamblajes NME según KGE, NSE y CRPS para los periodos de calibración y validación a escala diaria.

Cuenca	Periodo	NME~KGE			NME~NSE			NME~CRPS		
		CRatio	ABW	ADA	CRatio	ABW	ADA	CRatio	ABW	ADA
Cunday	Calibración	94.0	43.9	19.8	94.0	17.1	6.7	91.7	7.8	2.8
Cunday	Validación	94.7	60.2	27.1	94.2	23.1	9.0	91.1	8.9	3.2
San Pablo	Calibración	89.4	50.2	21.5	88.1	41.2	17.2	92.6	54.7	23.5
San Pablo	Validación	93.3	65.1	28.1	92.1	51.3	21.4	95.3	70.8	30.7
Prado	Calibración	92.2	118.5	25.8	95.3	122.7	26.5	94.1	116.9	25.4
Prado	Validación	93.9	121.1	32.8	73.2	125.3	37.2	70.0	119.7	35.5

Fuente: Elaboración propia

Tabla 7-6. Resultado evaluación de la incertidumbre por métricas en las tres cuencas para los tres nuevos mejores ensamblajes NME según KGE, NSE y CRPS para los periodos de calibración y validación a escala mensual.

Cuenca	Periodo	NME~KGE			NME~NSE			NME~CRPS		
		CRatio	ABW	ADA	CRatio	ABW	ADA	CRatio	ABW	ADA
Cunday	Calibración	3.8	1.2	3.2	10.6	1.9	2.9	9.9	1.8	2.9
Cunday	Validación	1.9	5.0	5.5	12.0	5.1	4.7	10.2	4.4	4.5
San Pablo	Calibración	17.1	2.5	4.3	23.5	3.6	4.0	0.0	1.3	4.9
San Pablo	Validación	21.3	3.2	4.3	30.6	3.5	4.2	1.9	1.7	5.0
Prado	Calibración	78.1	66.4	21.1	79.7	66.3	21.4	64.6	57.8	20.7
Prado	Validación	83.3	68.5	23.0	84.7	75.6	25.2	75.0	73.3	24.9

Fuente: Elaboración propia

Los resultados de los criterios ABW y ADA a escala mensual reflejan las magnitudes de las series observadas y simuladas en las cuales se reduce la variabilidad con respecto a la escala diaria. También, a escala mensual para las dos subcuencas se obtuvieron menores valores de CR con respecto a la escala diaria. Es decir, que el mejor desempeño de los modelos a escala mensual reduce la franja de incertidumbre, pero si el NME no se ajusta muy bien, el porcentaje de datos observados se ve muy castigado, se ve muy reducido.

8. CONCLUSIONES

- Fue construido un ensamble hidrológico multimodelo y multienfoque a escala mensual y diaria de la cuenca del río Prado (1.616 km²) y dos subcuencas Cunday (130 km²) y San Pablo (171.9 km²) como estrategia de mejoramiento en la estimación de caudales, a partir de 17 modelos hidrológicos (miembros) de diferentes enfoques: modelos basados en datos, conceptuales y físicos, escalas locales, regionales y globales.
- Los modelos locales implementados fueron cuatro. Dos de ellos mediante la estructura Deep Learning y la herramienta Keras. a) utilizando como inputs la precipitación, precipitación media móvil y la evapotranspiración se llamó KerasDeVos. b) utilizando la precipitación al tiempo, con rezago de un día y de dos días además del caudal rezagado un día y de dos días se denominó KerasBrochero.
- A escala mensual KerasDeVos, tuvo mejor desempeño en las subcuencas Cunday y San Pablo mientras que KerasBrochero fue mejor en la cuenca Prado. A escala diaria esta situación se invierte siendo KerasBrochero el de mejor desempeño en Cunday y San Pablo y en Prado KerasDeVos fue mejor. A pesar que la estructura de la red neuronal es la misma en ambos casos, la diferencia en el desempeño y comportamiento de los modelos se debió a las diferentes variables de entrada. Las variables rezagadas del modelo KerasBrochero, en general, representaron la dinámica hidrológica de los caudales diarios en las escalas espaciales evaluadas.
- Los otros dos modelos locales fueron implementados mediante SWAT. Con similar información de entrada como: el tipo de suelo, coberturas, terreno y climatología excepto por la precipitación. Este último forzamiento varió en los dos modelos, en uno corresponde a precipitación in-situ (Swat Pin-situ) y en el otro modelo corresponde a la precipitación distribuida del proyecto *earth2Observe* Colombia (Swat Pdistri).
- En las subcuencas a escala diaria y mensual la precipitación distribuida mejoró el desempeño del modelo SWAT. A escala mensual en las subcuencas se encontró un incremento en NSE que oscilo entre 0.56 y 0.73 frente a su similar Pin-situ en NSE -0.09 a 0.15. El procesamiento e interpolación espacial que tuvieron las precipitaciones permitieron una mejor asignación espacial de cada estación distribuida en cada subcuenca de SWAT logrando una mejor simulación de los caudales. Sin desconocer que a escala mensual se han logrado desempeños más altos en otras cuencas nacionales e internacionales.

- Los modelos SWAT tienen buen desempeño y hacen parte de los NME en las tres áreas de análisis a escala mensual y para las tres métricas, lo que no ocurre a escala diaria. En esta última escala, los modelos Swat Pin-situ sobreestiman los caudales producto de una alta precipitación en comparación con las magnitudes de las precipitaciones distribuidas.
- Contrastando los modelos locales, en la cuenca Prado a escala mensual tanto SWAT como DL-Keras tuvieron un desempeño similar. Si se tratase de seleccionar un modelo se pudiese decantar por el DL-Keras dado que demanda menos información y preparación de la misma, y el proceso de calibración está implícito en el entrenamiento de la red neuronal.
- De todas las posibles combinaciones de los 17 modelos se generaron 131.054 ensambles promedio por cada cuenca/subcuenca en las dos escalas temporales de análisis. Como resultado fueron seleccionados tres (3) mejores ensambles promedio (ME) por su desempeño según dos métricas determinísticas KGE y NSE, y una probabilística CRPS. Algunos de estos ensambles simples tuvieron un mejor desempeño que el mejor modelo (MM) a pesar de su baja representación de los caudales extremos tanto bajos como en altos.
- Los ME a escala de cuenca y subcuenca evaluados con las métricas determinísticas estuvieron conformados entre 2 y 6 miembros a escala diaria, mientras que a escala mensual oscilaron entre 2 y 4 miembros. Los ME para la métrica probabilística tuvo participación de 2 y 3 miembros a escala diaria y de 3 a 4 miembros a escala mensual. Los miembros que conformaron principalmente los ME fueron los modelos locales (es decir SWAT y Keras) y algunos regionales como VIC y MESH. Estos últimos modelos participaron en los ME a escala de cuenca porque la resolución espacial de resultados representaron de una forma aceptable los procesos hidrológicos, principalmente a escala diaria. Sin embargo, a escala de subcuenca estos y otros modelos regionales tendieron a sobreestimar los caudales.
- Los modelos globales de escala 0.5° no tuvieron participación dentro de los ensambles, ya que las magnitudes de sus series fueron superiores a los caudales observados en las subcuencas y cuenca Prado. Presumiblemente, se deba a la resolución espacial que, en general, alcanzan a tomar el cauce del río Magdalena que transporta caudales superiores a los 300 m³/s a la altura de la desembocadura del Prado y adicionalmente, estos modelos no fueron calibrados con los caudales observados (Rodríguez et al., 2016).

- Evaluando el desempeño de los 131.054 ensambles promedio según las métricas se observó que, con pocos miembros en los ensambles (entre 2 y 5), se encontraron los mejores ensambles ME, tanto para KGE y NSE, como CRPS. No obstante, para el mismo número de miembros se obtuvieron desempeños muy bajos de las métricas evaluadas, ya que en combinaciones podría resultar que ensamble estuviera conformado única o mayoritariamente por modelos globales.
- Los ME fueron evaluados por el método Modelo Bayesiano Promedio (BMA) para identificar el peso o participación de cada miembro en el ensamble. Con el valor de los pesos se generó una serie ponderada por cada métrica llamada Nuevo Mejor Ensamble (NME~KGE, NME~NSE y NME~CRPS). Como resultado se evidenció que a escala subcuena y nivel diario como mensual mejoraron la estimación de los caudales frente a al MM. Esto se debe a la diversidad de los miembros que componen cada ensamble, que temporal y espacialmente caracterizan a los procesos hidrológicos de una mejor forma, donde el peso de cada miembro refleja su capacidad a portar en la representación del fenómeno estudiado.
- No existe un único mejor ensamble y depende de la métrica de evaluación del desempeño y del uso que se le vaya a dar a las estimaciones. Los mejores ensambles según CRPS reflejaron un rango de incertidumbre menor haciéndolos más confiables frente a las otras dos métricas determinísticas utilizadas. CRPS considera la probabilidad de ocurrencia de un evento basado en la función de probabilidad de los miembros del ensamble para el paso de tiempo de interés, mientras que KGE o NSE relativizan los errores de las estimaciones mediante el caudal medio de toda la serie de tiempo en la cual se agrega mayor incertidumbre en la estimación.
- La construcción de un ensamble hidrológico puede tener ciertas ventajas frente a desarrollar un único modelo. Dado, que es más conveniente enfocarse en reportar la incertidumbre para tener simulaciones con un mayor grado de confiabilidad que son muy útiles para los administrados del recurso hídrico, en vez de dirigir grandes esfuerzos en desarrollar un “super” modelo.

9. LIMITACIONES DEL TRABAJO DESARROLLADO

- La serie de caudales de la estación Boquerón sobre el río Prado aguas abajo de la represa solo está disponible hasta el año 2002, ya que su funcionamiento fue suspendido por el IDEAM, lo que deja hasta la actualidad un gran periodo de tiempo sin datos observados que permita concluir, inferir o explicar mayores elementos del ciclo hidrológico dentro de la cuenca.
- La cantidad de datos faltantes de dos estaciones adicionales (Hda. Ruby y La Mora) ubicadas dentro de la cuenca río Prado hizo que no fueron tenidas en cuenta, pero que contribuirían a analizar en mejor manera el comportamiento de la cuenca.
- La serie de caudales turbinados de la represa HidroPrado está disponible desde el año 2007 a la fecha. Este registro es muy reciente y no coincide en ningún momento con la serie de la estación Boquerón que finalizó en el año 2002. Esto conlleva a que la regulación que hace la presa no haya podido ser considerada en la modelación hidrológica con SWAT.
- El bajo desempeño de algunos modelos globales y regionales, influenció que no fueron considerados como miembros en los ME. En el caso de los modelos globales está relacionado con la resolución espacial de los datos de caudal, mientras que en los modelos regionales el punto de calibración se encontraba sobre el río Magdalena.

10. INTERROGANTES ADICIONALES O PERSPECTIVAS DE INVESTIGACIÓN

- Realizar variaciones al modelo basado en datos DL-Keras para incluirlos al ensamble como nuevos miembros. Estas variaciones pueden ser a) utilizar DL-Keras otra vez, pero cambiando la red neuronal FNN por las múltiples opciones existentes b) utilizar la misma red neuronal FNN, pero en otras herramientas de DL. Esto no solo permitirá ampliar la diversidad del ensamble, sino permitirá indagar sobre la capacidad predictiva de las FNN frente a las otras redes neuronales.
- Debido a la participación de los modelos locales en casi todos los mejores ensambles sin importar su escala temporal, se podrían implementar otros modelos locales para analizar si los modelos aquí implementados fueron adecuados o si simplemente eran mejores que los modelos regionales y globales. De esta manera, se considera que generar otros ensambles con modelos de desempeños similares o mejores a los de los modelos SWAT y Deep Learning pueden robustecer ampliamente el ensamble.

- Establecer una estrategia de selección de modelos o miembros de un ensamble sin perder la capacidad de indagar en la incertidumbre. Esto se debe a que al utilizar la mayor cantidad posible de miembros el ensamble se beneficiará de la diversidad, que a su vez contribuye a reducir la incertidumbre. Pero, en un proyecto de investigación de decenas o centenas de miembros será desgastante técnica y computacionalmente la conformación de un ensamble.
- La estimación de los pesos en cada ensamble promedio ME que permitieron obtener posteriormente cada NME se realizó mediante BMA pero existen otros métodos de estimación de los pesos como: *Akaike information criterion averaging* (AICA), *a variant of the Granger-Ramanathan Averaging* (GRA) *method*, y *simple arithmetic mean* (SAM) (Broderick et al., 2016).
- Replicar el ensamble hidrológico realizado por De Vos (2013) con la base de datos MOPEX (Model Parameter Estimation Experiment) (Duan et al., 2006) utilizando la red neuronal planteada en este trabajo de grado (FNN en Keras), con el fin de contrastar el desempeño de esta red neuronal frente a los hallazgos de De Vos y otros autores porque sobre las cuencas o base de datos MOPEX, distintos grupos de investigación han desarrollado trabajos allí. Por lo tanto, múltiples estudios con la misma base de datos permitirán comparar en mejor manera la capacidad predictiva o de estimación de caudales de la red neuronal artificial tipo FNN mediante Keras aquí planteada.

11. BIBLIOGRAFÍA

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Corrado, G.S., Davis, A., Dean, J., Devin, M., Ghemawat, S., Goodfellow, I., Harp, A., Irving, G., Isard, M., Jozefowicz, R., Jia, Y., Kaiser, L., Kudlur, M., Levenberg, J., Mané, D., Schuster, M., Monga, R., Moore, S., Murray, D., Olah, C., Shlens, J., Steiner, B., Sutskever, I., Talwar, K., Tucker, P., Vanhoucke, V., Vasudevan, V., Viégas, F., Vinyals, O., Warden, P., Wattenberg, M., Wicke, M., Yu, Y., Zheng, X., 2015. TensorFlow Systems: Large-scale machine learning on heterogeneous.
- Abbaspour, K.C., Vaghefi, S.A., Srinivasan, R., 2017. A guideline for successful calibration and uncertainty analysis for soil and water assessment: A review of papers from the 2016 international SWAT conference. *Water (Switzerland)* 10. <https://doi.org/10.3390/w10010006>
- Abbaspour, K.C., Vejdani, M., Haghghat, S., Yang, J., 2007. SWAT-CUP Calibration and Uncertainty Programs for SWAT. fourth Int. SWAT Conf. 1596–1602. <https://doi.org/10.1007/s00402-009-1032-4>
- Abdullahi, J., Elkiran, G., 2017. Prediction of the future impact of climate change on reference evapotranspiration in Cyprus using artificial neural network, in: *Procedia Computer Science*. <https://doi.org/10.1016/j.procs.2017.11.239>
- Abrahart, R.J., Anctil, F., Coulibaly, P., Dawson, C.W., Mount, N.J., See, L.M., Shamseldin, A.Y., Solomatine, D.P., Toth, E., Wilby, R.L., 2012. Two decades of anarchy? Emerging themes and outstanding challenges for neural network river forecasting. *Prog. Phys. Geogr.* 36, 480–513. <https://doi.org/10.1177/0309133312444943>
- Agarwal, A., Akchurin, E., Basoglu, C., Chen, G., Cyphers, S., Droppo, J., Eversole, A., Guenter, B., Hillebrand, M., Hoens, R., Huang, X., Huang, Z., Ivanov, V., Kamenev, A., Kranen, P., Kuchaiev, O., Manousek, W., May, A., Mitra, B., Nano, O., Navarro, G., Orlov, A., Parthasarathi, H., Peng, B., Radmilac, M., Reznichenko, A., Seide, F., Seltzer, M.L., Slaney, M., Stolcke, A., Wang, H., Wang, Y., Yao, K., Yu, D., Zhang, Y., Zweig, G., 2014. An Introduction to Computational Networks and the Computational Network Toolkit. Microsoft Technical Report MSR-TR-2014-112.
- Al-Rfou, R., Alain, G., Almahairi, A., Angermueller, C., Bahdanau, D., Ballas, N., Bastien, F., Bayer, J., Belikov, A., Belopolsky, A., Bengio, Y., Bergeron, A., Bergstra, J., Bisson, V., Blecher Snyder, J., Bouchard, N., Boulanger-Lewandowski, N., Bouthillier, X., de Brébisson, A., Breuleux, O., Carrier, P.-L., Cho, K., Chorowski, J., Christiano, P., Cooijmans, T., Côté, M.-A., Côté, M., Courville, A., Dauphin, Y.N., Delalleau, O., Demouth, J., Desjardins, G., Dieleman, S., Dinh, L., Ducoffe, M., Dumoulin, V., Ebrahimi Kahou, S., Erhan, D., Fan, Z., Firat, O., Germain, M., Glorot, X., Goodfellow, I., Graham, M., Gulcehre, C., Hamel, P., Harlouchet, I., Heng, J.-P., Hidasi, B., Honari, S., Jain, A., Jean, S., Jia, K., Korobov, M., Kulkarni, V., Lamb, A., Lamblin, P., Larsen, E., Laurent, C., Lee, S., Lefrancois, S., Lemieux, S., Léonard, N., Lin, Z., Livezey, J.A., Lorenz, C., Lowin, J., Ma, Q., Manzagol, P.-A., Mastropietro, O., McGibbon, R.T., Memisevic, R., van Merriënboer, B., Michalski, V., Mirza, M., Orlandi, A., Pal, C., Pascanu, R., Pezeshki, M., Raffel, C., Renshaw, D., Rocklin, M., Romero, A., Roth, M., Sadowski, P., Salvatier, J., Savard, F., Schlüter, J., Schulman, J., Schwartz, G., Serban, I.V., Serdyuk, D., Shabanian, S., Simon, É., Spieckermann, S., Subramanyam, S.R., Sygnowski, J., Tanguay, J., van Tulder, G., Turian, J., Urban, S., Vincent, P., Visin, F., de Vries, H., Warde-Farley, D., Webb, D.J., Willson, M., Xu, K., Xue, L., Yao, L., Zhang, S., Zhang, Y., 2016. Theano: A {Python} framework for fast computation of mathematical expressions. arXiv e-prints [abs/1605.0](https://arxiv.org/abs/1605.0).
- Alizadeh, Z., Yazdi, J., Kim, J.H., Al-Shamiri, A.K., 2018. Assessment of machine learning

- techniques for monthly flow prediction. *Water (Switzerland)* 10, 1–24. <https://doi.org/10.3390/w10111676>
- Arboleda-Obando, P., 2018. Determinando los efectos del cambio climático y del cambio en usos del suelo en la Macro Cuenca Magdalena Cauca utilizando el modelo de suelo-superficie e hidrológico MESH.
- Arboleda-Obando, P., Duque, N., Vega, C., Zamora, D., Rodriguez, E., 2018. Multi-Structure Hydrological Ensemble to Improve Flow Daily Prediction in the Sumapaz River Basin, Colombia, in: HIC 2018. 13th International. pp. 62–53. <https://doi.org/10.29007/1112>
- Arnold, J.G., Moriasi, D.N., Gassman, P.W., Abbaspour, K.C., White, M.J., Srinivasan, R., Santhi, C., Harmel, R.D., Van Griensven, A., Liew, M W Van, Kannan, N., Jha, M.K., Harmel, D., Member, A., Liew, Michael W Van, 2012. SWAT: MODEL USE, CALIBRATION, AND VALIDATION. *Trans. ASABE* 55, 1491–1508.
- Assem, H., Ghariba, S., Makrai, G., Johnston, P., Gill, L., Pilla, F., 2017. Urban Water Flow and Water Level Prediction Based on Deep Learning. *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)* 10536 LNAI. https://doi.org/10.1007/978-3-319-71273-4_26
- Bai, J., Shen, Z., Yan, T., 2017. A comparison of single- and multi-site calibration and validation: a case study of SWAT in the Miyun Reservoir watershed, China. *Front. Earth Sci.* 11, 592–600. <https://doi.org/10.1007/s11707-017-0656-x>
- Balsamo, G., Viterbo, P., Beljaars, A., Van Den Hurk, B., Hirschi, M., Betts, A.K., Scipal, K., 2009. A Revised Hydrology for the ECMWF Model: Verification from Field Site to Terrestrial Water Storage and Impact in the Integrated Forecast System. *J. Hydrometeorol.* 10. <https://doi.org/10.1175/2008JHM1068.1>
- Bennett, J.C., Robertson, D.E., Shrestha, D.L., Wang, Q.J., Enever, D., Hapuarachchi, P., Tuteja, N.K., 2014. A System for Continuous Hydrological Ensemble Forecasting (SCHEF) to lead times of 9days. *J. Hydrol.* 519, 2832–2846. <https://doi.org/10.1016/j.jhydrol.2014.08.010>
- Beven, K.J., 2001. How far can we go in distributed hydrological modelling. *Distrib. Hydrol. Model.* 5, 255–278.
- Beven, K.J., 1989. Changing ideas in hydrology - The case of physically-based models. *J. Hydrol.* 105, 157–172.
- Bohn, T.J., Sonessa, M.Y., Lettenmaier, D.P., 2010. Seasonal Hydrologic Forecasting: Do Multimodel Ensemble Averages Always Yield Improvements in Forecast Skill? *J. Hydrometeorol.* 11. <https://doi.org/10.1175/2010JHM1267.1>
- Bowler, N.E., Arribas, A., Mylne, K.R., 2007. The benefits of multi-analysis and poor-man ' s ensembles.
- Brochero, D., 2013. Hydroinformatics and diversity in hydrological ensemble prediction systems 175.
- Broderick, C., Matthews, T., Wilby, R.L., Bastola, S., Murphy, C., 2016. Transferability of hydrological models and ensemble averaging methods between contrasting climatic periods. *Water Resour. Res.* 52, 8343–8373. <https://doi.org/10.1002/2016WR018850>
- Burn et al, 1999. Short term streamflow forecasting using artificial neural networks. *J. Hydrol.* 214, 32–48. [https://doi.org/10.1016/S0022-1694\(98\)00242-X](https://doi.org/10.1016/S0022-1694(98)00242-X)
- Chollet, F., 2015. deep Learning with Python. Manning Publications Co. <https://doi.org/citeulike-article-id:10054678>
- Chou, Y.-M., Polansky, A.M., Mason, R.L., 1998. Transforming Non-Normal Data to Normality in Statistical Process Control. *J. Qual. Technol.* 30, 133–141. <https://doi.org/10.1080/00224065.1998.11979832>
- Cluckie, I.D., Xuan, Y., Wang, Y., 2006. Uncertainty analysis of hydrological ensemble forecasts in a distributed model utilising short-range rainfall prediction. *Hydrol. Earth Syst. Sci. Discuss.* 3, 3211–3237. <https://doi.org/10.5194/hessd-3-3211-2006>

- Cortolima, 2005. Plan de ordenacion y manejo cuenca Rio Prado 34–51.
- Dance, S.L., Zou, Q.P., 2010. *HESSE Opinions* “Ensembles, uncertainty and flood prediction.” *Hydrol. Earth Syst. Sci. Discuss.* 7, 3591–3611. <https://doi.org/10.5194/hessd-7-3591-2010>
- Dawson, C.W., Abrahart, R.J., See, L.M., 2010. HydroTest: Further development of a web resource for the standardised assessment of hydrological models. *Environ. Model. Softw.* 25, 1481–1482. <https://doi.org/10.1016/j.envsoft.2009.01.001>
- De Vos, N.J., 2013. Echo state networks as an alternative to traditional artificial neural networks in rainfall-runoff modelling. *Hydrol. Earth Syst. Sci.* 17, 253–267. <https://doi.org/10.5194/hess-17-253-2013>
- Decharme, B., Alkama, R., Douville, H., 2010. Global Evaluation of the ISBA-TRIP Continental Hydrological System. Part II: Uncertainties in River Routing Simulation Related to Flow Velocity and Groundwater Storage. *Am. Meteorol. Soc.*
- Dietrich, J., Trepte, S., Wang, Y., Schumann, A.H., Voß, F., Hesser, F.B., Denhard, M., 2008. Combination of different types of ensembles for the adaptive simulation of probabilistic flood forecasts: Hindcasts for the Mulde 2002 extreme event. *Nonlinear Process. Geophys.* 15, 275–286. <https://doi.org/10.5194/npg-15-275-2008>
- Döll, P., Fiedler, K., Zhang, J., 2009. Global-scale analysis of river flow alterations due to water withdrawals and reservoirs. *Hydrol. Earth Syst. Sci. Discuss.* 6, 4773–4812.
- Dong, L., Xiong, L., Yu, K., 2013. Uncertainty Analysis of Multiple Hydrologic Models Using the Bayesian Model Averaging Method. *J. Appl. Math.* 2013, 1–11. <https://doi.org/10.1155/2013/346045>
- Duan, Q., Schaake, J., Andréassian, V., Franks, S., Goteti, G., Gupta, H. V., Gusev, Y.M., Habets, F., Hall, A., Hay, L., Hogue, T., Huang, M., Leavesley, G., Liang, X., Nasonova, O.N., Noilhan, J., Oudin, L., Sorooshian, S., Wagener, T., Wood, E.F., 2006. Model Parameter Estimation Experiment (MOPEX): An overview of science strategy and major results from the second and third workshops. *J. Hydrol.* 320, 3–17. <https://doi.org/10.1016/j.jhydrol.2005.07.031>
- Fenicia, F., Savenije, H.H.G., Matgen, P., Pfister, L., 2008. Understanding catchment behavior through stepwise model concept improvement 44, 1402. <https://doi.org/10.1029/2006WR005563>
- Flörke, M., Kynast, E., Bärlund, I., Eisner, S., Wimmer, F., Alcamo, J., 2013. Domestic and industrial water uses of the past 60 years as a mirror of socio-economic development: A global simulation study. *Glob. Environ. Chang.* 23, 144–156. <https://doi.org/10.1016/j.gloenvcha.2012.10.018>
- Fundel, F., Jörg-Hess, S., Zappa, M., 2013. Monthly hydrometeorological ensemble prediction of streamflow droughts and corresponding drought indices. *Hydrol. Earth Syst. Sci.* 17, 395–407. <https://doi.org/10.5194/hess-17-395-2013>
- García-Moya, J., Callado, A., Santos, C., Santos, D., Simarro, J., 2007. Multi Multi--model Ensemble for Short model Ensemble for Short--Range Predictability Range Predictability.
- García-Moya, J.A., Callado, A., Escriba, P., Santos, C., Santos-Munoz, D., Simarro, J., 2011. Predictability of short-range forecasting: A multimodel approach. *Tellus, Ser. A Dyn. Meteorol. Oceanogr.* 63, 550–563. <https://doi.org/10.1111/j.1600-0870.2010.00506.x>
- Gassman, P.W., Sadeghi, A.M., Srinivasan, R., 2014. Applications of the SWAT Model Special Section: Overview and Insights. *J. Environ. Qual.* 43, 1. <https://doi.org/10.2134/jeq2013.11.0466>
- Ghaffari, G., Keesstra, S., Ghodousi, J., Ahmadi, H., 2010. SWAT-simulated hydrological impact of land-use change in the Zanzanrood Basin, Northwest Iran. *Hydrol. Process.* 24, 892–903. <https://doi.org/10.1002/hyp.7530>
- Gneiting, T., Raftery, A.E., 2007. Strictly Proper Scoring Rules, Prediction, and Estimation. <https://doi.org/10.1198/016214506000001437>

- Grath, B., 2016. Simulation of Discharge and Nitrate-Nitrogen Loads in the Raab Catchment with the hydrological model SWAT.
- Gupta, H. V., Kling, H., Yilmaz, K.K., Martinez, G.F., 2009. Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *J. Hydrol.* 377, 80–91. <https://doi.org/10.1016/j.jhydrol.2009.08.003>
- Ha, L.T., Bastiaanssen, W.G.M., van Griensven, A., van Dijk, A.I.J.M., Senay, G.B., 2017. SWAT-CUP for Calibration of Spatially Distributed Hydrological Processes and Ecosystem Services in a Vietnamese River Basin Using Remote Sensing. *Hydrol. Earth Syst. Sci.* 1–35. <https://doi.org/10.5194/hess-2017-251>
- Habte, K., Mamo, M., Jain, M.K., 2013. Runoff and Sediment Modeling Using SWAT in Gumera Catchment, Ethiopia. *Open J. Mod. Hydrol.* 2013, 196–205. <https://doi.org/10.4236/ojmh.2013.34024>
- Hargreaves, G.H., Samani, Z.A., 1985. Reference Crop Evapotranspiration from Temperature. *Appl. Eng. Agric.* 1, 96–99. <https://doi.org/10.13031/2013.26773>
- Heo, S., Kim, N., Park, Y., Kim, J., Ahn, J., Kyoung, K.K., Lim, J., 2008. Evaluation of Effects on SWAT Simulated Hydrology and Sediment Behaviors of SWAT Watershed Delineation using SWAT ArcView GIS Extension Patch. *J. Korean Soc. Water Quality* 24, 147–155.
- Huang, A., Vega-Westhoff, B., Sriver, R.L., 2019. Analyzing El Niño-Southern Oscillation Predictability Using Long-Short-Term-Memory Models. *Earth Sp. Sci.* 1–10. <https://doi.org/10.1029/2018ea000423>
- IGAC, 2004. Estudio General de Suelos y Zonificación de Tierras Departamento del Tolima.
- Iversen, T., Deckmyn, A., Santos, C., Sattler, K., Bremnes, J.B., Feddersen, H., Frogner, I.L., 2011. Evaluation of 'GLAMEPS'-a proposed multimodel EPS for short range forecasting. *Tellus, Ser. A Dyn. Meteorol. Oceanogr.* 63, 513–530. <https://doi.org/10.1111/j.1600-0870.2010.00507.x>
- JAXA/METI, 2010. ALOS PALSAR_Radiometric_Terrain_Corrected_high_res; includes material.
- Jeong, D.-I., Kim, Y.-O., 2005. Rainfall-runoff models using artificial neural networks for ensemble streamflow prediction. *Hydrol. Process.* 19, 3819–3835. <https://doi.org/10.1002/hyp.5983>
- Kan, G., Yao, C., Li, Q., Li, Z., Yu, Z., Liu, Z., Ding, L., He, X., Liang, K., 2015. Improving event-based rainfall-runoff simulation using an ensemble artificial neural network based hybrid data-driven model. *Stoch. Environ. Res. Risk Assess.* 29, 1345–1370. <https://doi.org/10.1007/s00477-015-1040-6>
- Khalid, K., Ali, M.F., Rahman, N.F.A., Mispan, M.R., Haron, S.H., Othman, Z., Bachok, M.F., 2016. Sensitivity Analysis in Watershed Model Using SUFI-2 Algorithm. *Procedia Eng.* 162, 441–447. <https://doi.org/10.1016/j.proeng.2016.11.086>
- Khan, M.S., Coulibaly, P., 2006. Application of Support Vector Machine in Lake Water. *J. Hydrol. Eng.* 11, 199–205.
- Kouwen, N., Soulis, E.D., Pietroniro, A., Donald, J., Harrington, R.A., 1993. Grouped response units for distributed hydrologic modelling By N . Kouwen , I Member , ASCE , E . D . Soulis , 2 A . Pietronirofl J . Donald , 4 captured using small subbasin elements often called hydrologic response units (HRUs) (Leavesley and Stannar. *J. Water Resour. Plan. Manag.* 119, 289–305.
- Krinner, G., Viovy, N., de Noblet-Ducoudré, N., Ogée, J., Polcher, J., Friedlingstein, P., Ciais, P., Sitch, S., Prentice, I.C., 2005. A dynamic global vegetation model for studies of the coupled atmosphere-biosphere system. *Global Biogeochem. Cycles* 19, 1–33. <https://doi.org/10.1029/2003GB002199>
- Krzysztofowicz, R., 2001. The case for probabilistic forecasting in hydrology. *J. Hydrol.* 249, 2–9. [https://doi.org/10.1016/S0022-1694\(01\)00420-6](https://doi.org/10.1016/S0022-1694(01)00420-6)
- Lecun, Y., Bengio, Y., Hinton, G., 2015. Deep learning. *Nature* 521, 436–444.

- <https://doi.org/10.1038/nature14539>
- Li, W., Sankarasubramanian, A., Ranjithan, R.S., Sinha, T., 2016. Role of multimodel combination and data assimilation in improving streamflow prediction over multiple time scales. *Stoch. Environ. Res. Risk Assess.* 30, 2255–2269. <https://doi.org/10.1007/s00477-015-1158-6>
- Liang, X., Lettenmaier, D.P., Wood, E.F., Burges, S.J., 1994. A simple hydrologically based model of land surface water and energy fluxes for general circulation models. *J. Geophys. Res.* 99, 415–429.
- Maier, H.R., Dandy, G.C., 2000. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environ. Model. Softw.* 15, 101–124.
- Mallat, S., 2016. Understanding deep convolutional networks. <https://doi.org/10.1098/rsta.2015.0203>
- Marçais, J., de Dreuzy, J.R., 2017. Prospective Interest of Deep Learning for Hydrological Inference. *Groundwater* 55, 688–692. <https://doi.org/10.1111/gwat.12557>
- Marty, R., Zin, I., Obled, C., 2013. Sensitivity of hydrological ensemble forecasts to different sources and temporal resolutions of probabilistic quantitative precipitation forecasts: Flash flood case studies in the C??vennes-Vivarais region (Southern France). *Hydrol. Process.* 27, 33–44. <https://doi.org/10.1002/hyp.9543>
- Mcmillan, H., Krueger, T., Freer, J., 2012. Benchmarking observational uncertainties for hydrology: Rainfall, river discharge and water quality. *Hydrol. Process.* 26, 4078–4111. <https://doi.org/10.1002/hyp.9384>
- Montgomery, J.M., Hollenbach, F.M., Ward, M.D., 2016. Package “EBMAforecast.”
- Nash, J.E., Sutcliffe, J. V., 1970. River flow forecasting through conceptual models part I - A discussion of principles. *J. Hydrol.* 10, 282–290. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)
- Neitsch, S., Arnold, J.G., Kiniry, J., Williams, J., 2011. Soil & Water Assessment Tool Theoretical Documentation Version 2009. Texas Water Resour. Inst. 1–647. <https://doi.org/10.1016/j.scitotenv.2015.11.063>
- Nowak, W., 2009. Best unbiased ensemble linearization and the quasi-linear Kalman ensemble generator. *Water Resour. Res.* 45, 1–17. <https://doi.org/10.1029/2008WR007328>
- Palmer, T., Barkmeijer, J., Buizza, R., Petroliajgis, T., 1997. The ECMWF ensemble prediction system. *Meteorol. Appl.* 301–304. <https://doi.org/10.1017/CBO9780511617652.018>
- Pierce, D., 2017. Package “ncdf4” Title Interface to Unidata netCDF (Version 4 or Earlier) Format Data Files.
- Pietroniro, A., Fortin, V., Kouwen, N., Neal, C., Turcotte, R., Davison, B., Verseghy, D., Soulis, E.D., Caldwell, R., Evora, N., Pellerin, P., 2007. Development of the MESH modelling system for hydrological ensemble forecasting of the Laurentian Great Lakes at the regional scale. *Hydrol. Earth Syst. Sci.* 11, 1279–1294. <https://doi.org/10.5194/hess-11-1279-2007>
- Qu, B., Zhang, X., Pappenberger, F., Zhang, T., Fang, Y., 2017. Multi-model grand ensemble hydrologic forecasting in the Fu river basin using Bayesian model averaging. *Water (Switzerland)* 9. <https://doi.org/10.3390/w9020074>
- Raftery, A.E., Gneiting, T., Balabdaoui, F., Polakowski, M., 2005. Using Bayesian Model Averaging to Calibrate Forecast Ensembles.
- Regonda, S.K., Rajagopalan, B., Clark, M., Zagana, E., 2006. A multimodel ensemble forecast framework: Application to spring seasonal flows in the Gunnison River Basin. *Water Resour. Res.* 42, 1–14. <https://doi.org/10.1029/2005WR004653>
- Rodell, B.Y.M., Houser, P.R., Jambor, U., Gottschalck, J., Mitchell, K., Meng, C., Arsenault, K., Cosgrove, B., Radakovich, J., Bosilovich, M., Entin, J.K., Walker, J.P., Lohmann, D., Toll, D., 2004. THE GLOBAL LAND DATA ASSIMILATION SYSTEM This powerful new land

- surface modeling system integrates data from advanced observing systems to support improved forecast model initialization and hydrometeorological investigations. *Bull. Amer. Meteor. Soc.* 85, 381–394. <https://doi.org/10.1175/BAMS-85-3-381>
- Rodríguez, E., Sánchez, I., Duque, N., Arboleda, P., Vega, C., Zamora, D., López, P., Kaune, A., Werner, M., García, C., Burke, S., 2019. Combined Use of Local and Global Hydro Meteorological Data with Hydrological Models for Water Resources Management in the Magdalena - Cauca Macro Basin – Colombia. *Water Resour. Manag.* <https://doi.org/10.1007/s11269-019-02236-5>
- Rodríguez, E., Sánchez, I.C., Duque, N., Arboleda, P., Vega, C., Zamora, D., Lopez, P., Kaune, A., Werner, M., García, C., Burke, S., 2019. Combined use of local and global hydrometeorological data with hydrological models for water resources management in the Magdalena - Cauca macrobasin - Colombia. *Water Resour. Manag.* Aceptado.
- Rodríguez, E., Werner, M., Sánchez, I., Ramírez, W., Zamora, D., Duque, N., Arboleda, P., 2016. El proyecto Earth2Observe y su caso de estudio en la Macrocuena Magdalena – Cauca. Colombia. Xxvii Congr. Latinoam. Hidráulica.
- Rostamian, R., Jaleh, A., Afyuni, M., Mousavi, S.F., Heidarpor, M., Jalalian, A., Abbaspour, K.C., 2008. Application of a SWAT model for estimating runoff and sediment in two mountainous basins in central Iran. *Hydrol. Sci. J.* 53, 977–988. <https://doi.org/10.1623/hysj.53.5.977>
- Roulin, E., Vannitsem, S., 2005. Skill of Medium-Range Hydrological Ensemble Predictions.
- Schellekens, J., Dutra, E., Martínez-De La Torre, A., Balsamo, G., Van Dijk, A., Sperna Weiland, F., Minvielle, M., Calvet, J.C., Decharme, B., Eisner, S., Fink, G., Flörke, M., Peßenteiner, S., Van Beek, R., Polcher, J., Beck, H., Orth, R., Calton, B., Burke, S., Dorigo, W., Weedon, G.P., 2017. A global water resources ensemble of hydrological models: The earth2Observe Tier-1 dataset. *Earth Syst. Sci. Data* 9, 389–413. <https://doi.org/10.5194/essd-9-389-2017>
- Scher, S., 2018. Toward Data-Driven Weather and Climate Forecasting: Approximating a Simple General Circulation Model With Deep Learning. *Geophys. Res. Lett.* 45, 12,616–12,622. <https://doi.org/10.1029/2018GL080704>
- Seiller, G., Anctil, F., Roy, R., 2017. Design and experimentation of an empirical multistructure framework for accurate, sharp and reliable hydrological ensembles. *J. Hydrol.* 552, 313–340.
- Sharma, S., Reed, S., Mejia, A., Siddique, R., Ahnert, P., 2019. Hydrological Model Diversity Enhances Streamflow Forecast Skill at Short- to Medium-Range Timescales. *Water Resour. Res.* 1–21. <https://doi.org/10.1029/2018wr023197>
- Shen, C., 2018. A trans-disciplinary review of deep learning research and its relevance for water resources scientists. *Civ. Environ. Eng.* 1–66.
- Singh, P., 2013. Indian summer monsoon rainfall (ISMR) forecasting using time series data: A fuzzy-entropy-neuro based expert system. *Geosci. Front.*
- Solomatine, D.P., Shrestha, D.L., 2009. A novel method to estimate model uncertainty using machine learning techniques. *Water Resour. Res.* 45, 1–16. <https://doi.org/10.1029/2008WR006839>
- Surowiecki, J., 2004. *The Wisdom of Crowds*. First Anchor Books Edition.
- Sutanudjaja, E.H., van Beek, R., Wanders, N., Wada, Y., C Bosmans, J.H., Drost, N., van der Ent, R.J., M de Graaf, I.E., Hoch, J.M., de Jong, K., Karszenberg, D., López López, P., Peßenteiner, S., Schmitz, O., Straatsma, M.W., Vannamettee, E., Wisser, D., P Bierkens, M.F., Sutanudjaja EHSutanudjaja, E.H., 2018. PCR-GLOBWB 2: a 5 arcmin global hydrological and water resources model. *Geosci. Model Dev* 11, 2429–2453. <https://doi.org/10.5194/gmd-11-2429-2018>
- Tao, Y., Gao, X., Hsu, K., Sorooshian, S., Ihler, A., 2016. A Deep Neural Network Modeling Framework to Reduce Bias in Satellite Precipitation Products. *J. Hydrometeorol.* 17, 931–

945. <https://doi.org/10.1175/JHM-D-15-0075.1>
- Thapa, B.R., Ishidaira, H., Pandey, V.P., Shakya, N.M., 2017. A multi-model approach for analyzing water balance dynamics in Kathmandu Valley, Nepal. *J. Hydrol. Reg. Stud.* 9, 149–162. <https://doi.org/10.1016/j.ejrh.2016.12.080>
- Thiboult, A., Anctil, F., Boucher, M.A., 2016. Accounting for three sources of uncertainty in ensemble hydrological forecasting. *Hydrol. Earth Syst. Sci.* 20, 1809–1825. <https://doi.org/10.5194/hess-20-1809-2016>
- Tian, Y., Xu, Y.P., Yang, Z., Wang, G., Zhu, Q., 2018. Integration of a parsimonious hydrological model with recurrent neural networks for improved streamflow forecasting. *Water (Switzerland)* 10. <https://doi.org/10.3390/w10111655>
- Toth, E., Brath, A., Montanari, A., 2000. Comparison of short-term rainfall prediction models for real-time flood forecasting.
- Toth, Z., Kalnay, E., 1997. Ensemble Forecasting at NCEP and the Breeding Method. *Mon. Weather Rev.* 125, 3297–3319. [https://doi.org/10.1175/1520-0493\(1997\)125<3297:EFANAT>2.0.CO;2](https://doi.org/10.1175/1520-0493(1997)125<3297:EFANAT>2.0.CO;2)
- Van Der Knijff, J.M., Younis, J., De Roo, A.P.J., 2008. LISFLOOD: a GIS-based distributed model for river basin scale water balance and flood simulation. *Geogr. Inf. Sci.* 24, 189–212. <https://doi.org/10.1080/13658810802549154>
- Van Dijk, A.I.J.M., 2010. The Australian Water Resources Assessment System Technical Report 3. Landscape Model (version 0.5) Technical Description. . CSIRO: Water for a Healthy Country National Research Flagship.
- Velázquez, J.A., Anctil, F., Ramos, M.H., Perrin, C., 2011. Can a multi-model approach improve hydrological ensemble forecasting? A study on 29 French catchments using 16 hydrological model structures. *Adv. Geosci.* 29, 33–42. <https://doi.org/10.5194/adgeo-29-33-2011>
- Verseghy, D.L., 2000. The Canadian land surface scheme (CLASS): Its history and future. <https://doi.org/10.1080/07055900.2000.9649637>
- Vie, B., Molinie, G., Nuissier, O., Vincendon, B., Ducrocq, V., Bouttier, F., Richard, E., 2012. Hydro-meteorological evaluation of a convection-permitting ensemble prediction system for Mediterranean heavy precipitating events. *Nat. Hazards Earth Syst. Sci.* 12, 2631–2645. <https://doi.org/10.5194/nhess-12-2631-2012>
- Weber, J.F., Ocampo, S.B., 2019. Calibración del modelo hidrológico SWAT para una cuenca de la región serrana de Córdoba (Argentina). *Aqua-LAC* 11, 34–53. <https://doi.org/10.29104/phi-aqualac/2019-v11-1-03>
- Wei, M., Toth, Z., Wobus, R., Zhu, Y., Bishop, C.H., Wang, X., 2006. Ensemble Transform Kalman Filter-based ensemble perturbations in an operational global prediction system at NCEP. *Tellus, Ser. A Dyn. Meteorol. Oceanogr.* 58, 28–44. <https://doi.org/10.1111/j.1600-0870.2006.00159.x>
- Wilks, D.S., 1995. *Statistical Methods in the Atmospheric Sciences*. San Diego.
- Xu, C., 2002. *Hydrologic Models*. Report 72, 1–168. <https://doi.org/PNR61>
- Yang, J., Reichert, P., Abbaspour, K.C., Xia, J., Yang, H., 2008. Comparing uncertainty analysis techniques for a SWAT application to the Chaohe Basin in China. *J. Hydrol.* 358, 1–23. <https://doi.org/10.1016/j.jhydrol.2008.05.012>
- Zhang, D., Hølland, E.S., Lindholm, G., Ratnaweera, H., 2017. Hydraulic modeling and deep learning based flow forecasting for optimizing inter catchment wastewater transfer. <https://doi.org/10.1016/j.jhydrol.2017.11.029>
- Zhang, D., Lindholm, G., Ratnaweera, H., 2018. Use long short-term memory to enhance Internet of Things for combined sewer overflow monitoring. *J. Hydrol.* 556, 409–418. <https://doi.org/10.1016/j.jhydrol.2017.11.018>

12. ANEXO 1. LEYENDA DEL MAPA DE SUELOS

Los suelos de la cuenca del río Prado, Figura 6-5, son los correspondientes a los determinados en el Estudio General de Suelos y Zonificación de Tierras Departamento del Tolima (IGAC, 2004). Sus definiciones y características son mencionadas a continuación según el mapa de suelos de escala 1:100.000:

MKA: paisaje de montaña con un clima frío húmedo y muy húmedo de relieve estructural e irregular, de pendientes moderadamente escarpados, largas y de erosión ligera. Con suelos superficiales, bien drenados, texturas gruesas, muy ácidos, regulares en materia orgánica y fertilidad muy baja.

MKH: paisaje de montaña con un clima frío húmedo y muy húmedo de relieve ligero a moderadamente escarpado, pendientes cortas, con recubrimiento de cenizas volcánicas. Con suelos superficiales, bien a excesivamente drenados, de texturas medias a finas; ácidos, medios a altos en materia orgánica y de fertilidad baja a muy baja.

MQA: paisaje de montaña con un clima medio húmedo y muy húmedo de relieve moderado a fuertemente escarpado, pendientes largas con erosión ligera, moderada y severa.

SQL: paisaje de montaña con un clima medio húmedo y muy húmedo de relieve fuertemente ondulado y moderadamente escarpado, pendientes cortas, localmente con piedra superficial y erosión ligera. Con suelos profundos, bien drenados de texturas medias a finas, ácidos, altos en materia orgánica y de fertilidad moderada.

MQM: paisaje de montaña con un clima medio húmedo y muy húmedo de relieve moderadamente inclinado, moderada a fuertemente quebrado y escarpado, pendientes cortas, erosión moderada y pedregosidad superficial. Con suelos profundos y superficiales; bien drenados, de texturas finas y gruesas; fuertemente ácidos y de fertilidad baja.

MQO: paisaje de montaña con un clima medio húmedo y muy húmedo de relieve de superficies ligeramente inclinadas y largas, angostas, sujetas a inundaciones ocasionales. Con suelos moderadamente profundos, imperfectamente drenados, de texturas variables; ligeramente ácidos y de fertilidad baja.

MVA: paisaje de montaña con un clima cálido húmedo de relieve moderado a fuertemente escarpado, erosión moderada y severa. Con suelos superficiales a moderadamente profundos, de texturas finas y gruesas, ácidos y fertilidad baja.

MVC: Paisaje de montaña con un clima cálido húmedo de relieve ondulado, moderadamente escarpado, pendientes cortas, erosión ligera, moderada a severa; ocasionalmente pedregosidad superficial. Con suelos moderadamente profundos y profundos, bien drenados, ácidos, bajos en materia orgánica y de fertilidad baja.

MWA: paisaje de montaña con un clima cálido seco de relieve estructural, disimétrico de pendientes fuertemente quebradas, moderada a fuertemente escarpadas con afloramientos ocasionales de roca y erosión moderada a severa. Con suelos muy superficiales, excesivamente drenados, de texturas gruesas y medias, reacción neutra, pobres en materia orgánica y fertilidad muy baja.

MWG: paisaje de montaña con un clima cálido seco de relieve fuertemente ondulado, moderadamente quebrado, pendientes cortas, frecuente pedregosidad superficial y erosión ligera a moderada. Son suelos moderadamente profundos y superficiales, de texturas finas, ligeramente ácidos y de fertilidad moderada.

MWH: paisaje de montaña con un clima cálido seco de relieve fuertemente quebrado de pendientes cortas y erosión moderada. Son suelos superficiales a moderadamente profundos, de texturas medias y finas, bien drenados, ligeramente ácidos y de fertilidad baja.

PWB: paisaje de piedemonte con un clima cálido seco de relieve complejo, ligera a moderadamente inclinado y moderada a fuertemente ondulado, ocasionalmente con afloramientos rocosos, erosión ligera a moderada. Son suelos profundos y muy superficiales, bien drenados de reacción neutra, muy pobres en materia orgánica y de fertilidad moderada.

PWK: paisaje de piedemonte con un clima cálido seco de relieve plano a ligeramente inclinado, sin erosión aparente. Son suelos moderadamente profundos, moderadamente bien drenados de textura variables, ligeramente ácidos y alcalinos y de fertilidad moderada.

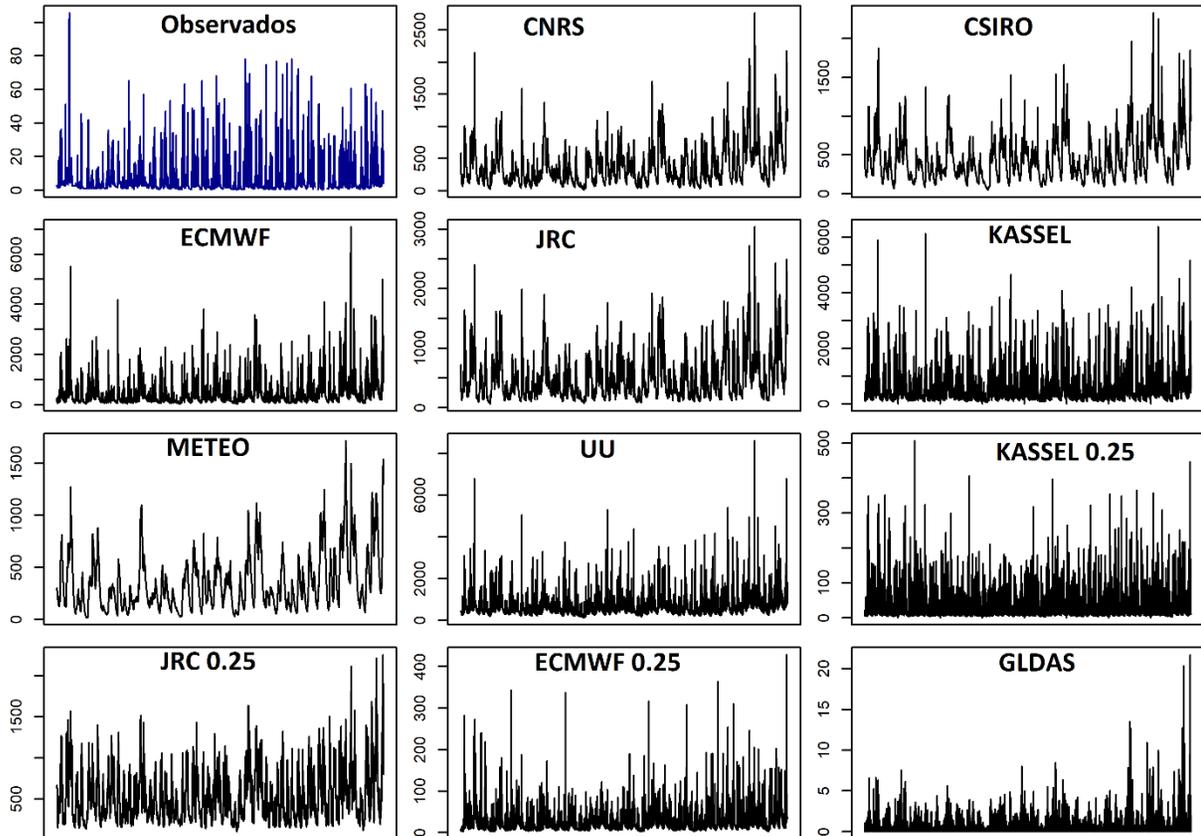
VWC: paisaje de valle con un clima cálido seco de relieve plano a ligeramente plano, expuesto a inundaciones ocasionales, localizadas. Son suelos profundos a moderadamente profundos, bien a moderadamente bien drenados, de texturas finas y medianas y fertilidad moderada a alta.

CA corresponde a cuerpos de agua y ZU a zonas urbanas.

13. ANEXO 2. HIDRÓGRAFAS DE MODELOS ESCALA DIARIA Y MENSUAL

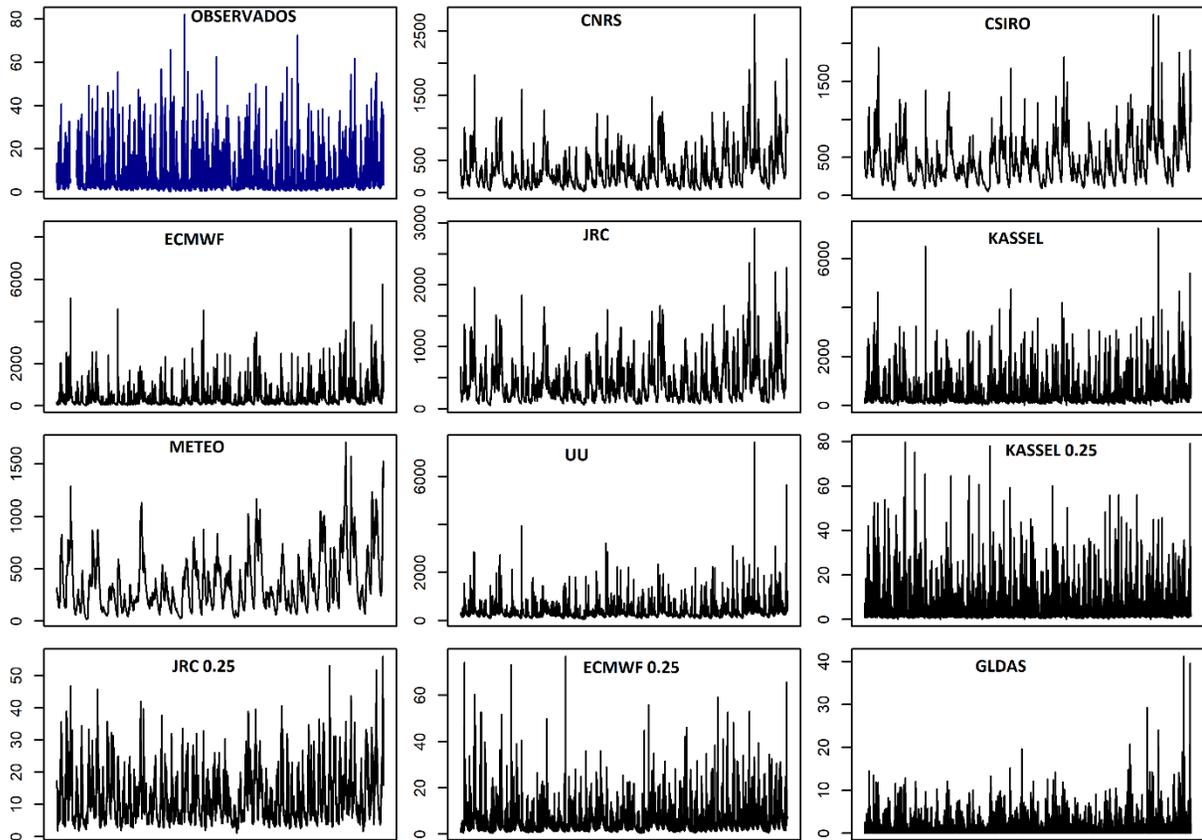
Caudales de cada modelo (miembro del ensamble) y escala diaria y mensual.

Figura 13-1. Series de caudales de modelos globales escala diaria cuenca Cunday periodo de 1981-2011



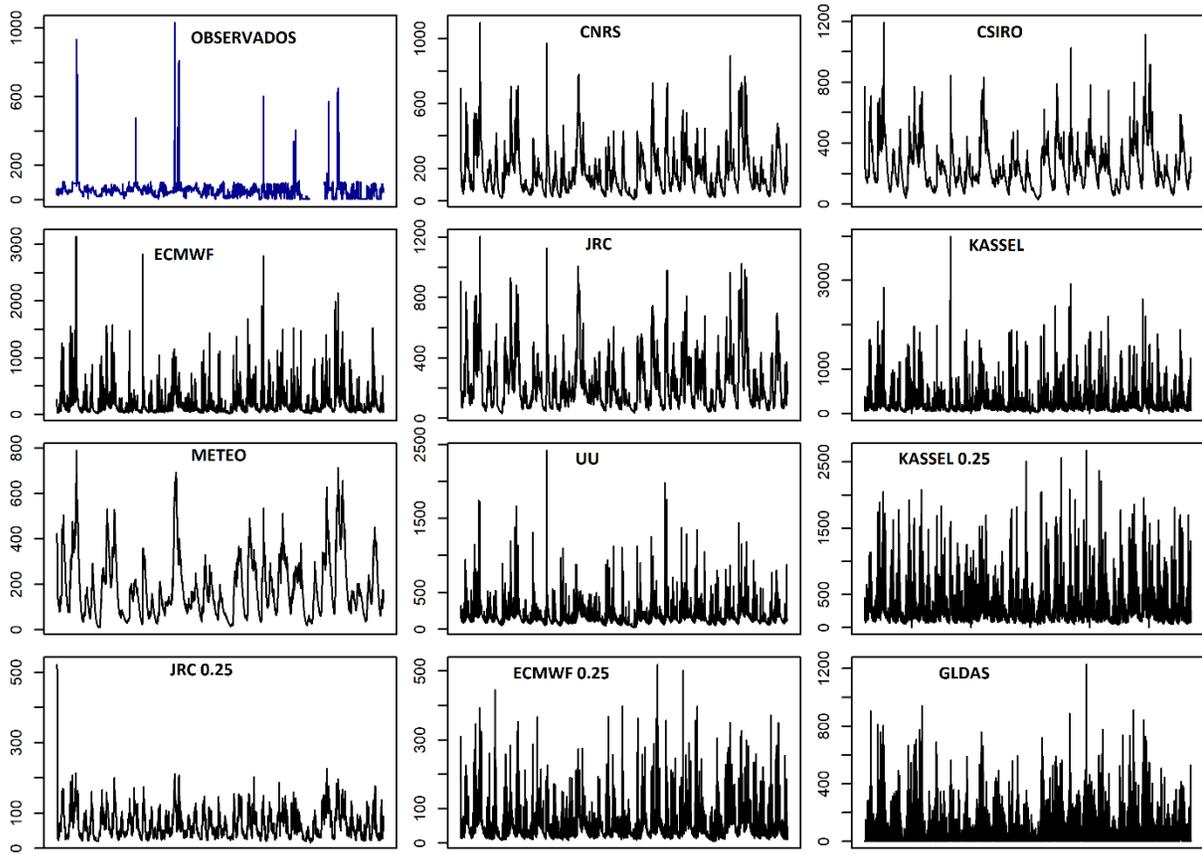
Fuente: Elaboración propia

Figura 13-2. Series de caudales modelos globales escala diaria cuenca San Pablo periodo de 1981-2011



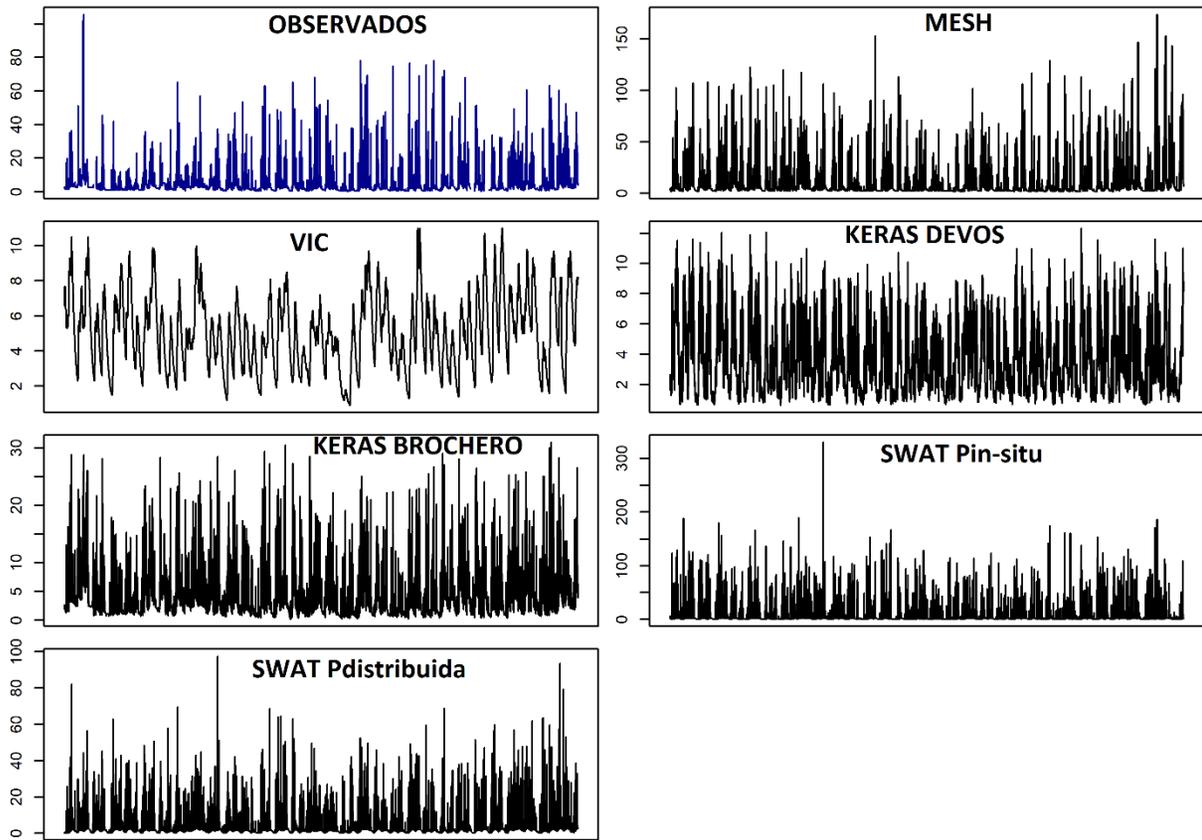
Fuente: Elaboración propia

Figura 13-3. Series de caudales modelos globales escala diaria cuenca Prado periodo de 1981-2002



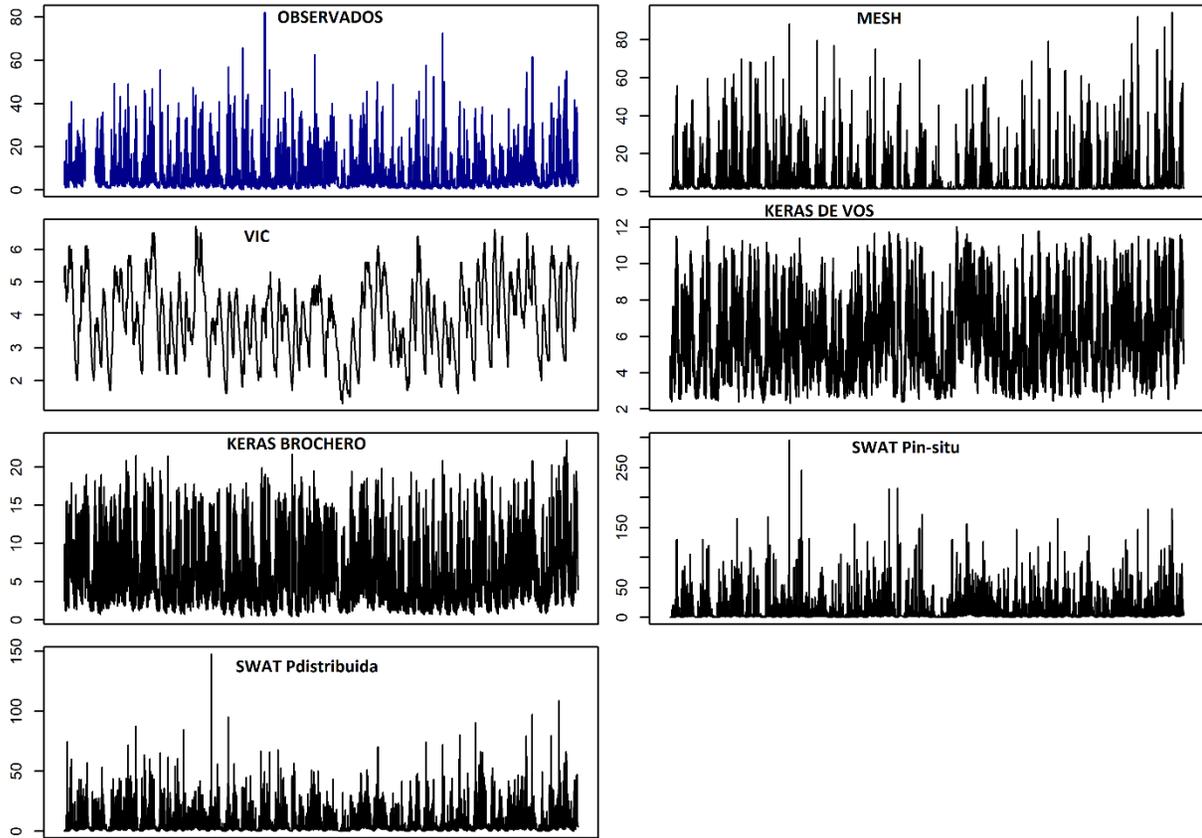
Fuente: Elaboración propia

Figura 13-4. Series de caudales de modelos regionales y locales escala diaria cuenca Cunday periodo de 1981-2011



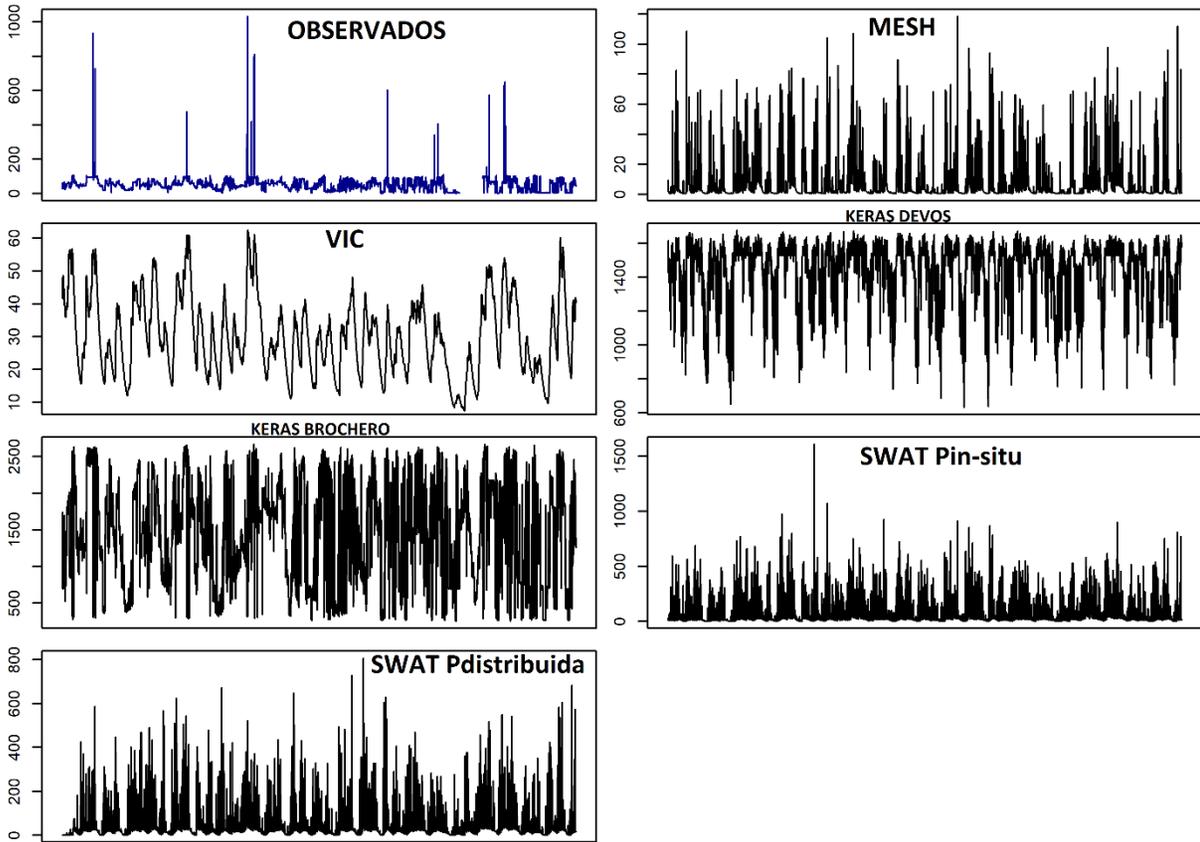
Fuente: Elaboración propia

Figura 13-5. Series de caudales modelos regionales y locales escala diaria cuenca San Pablo periodo de 1981-2011



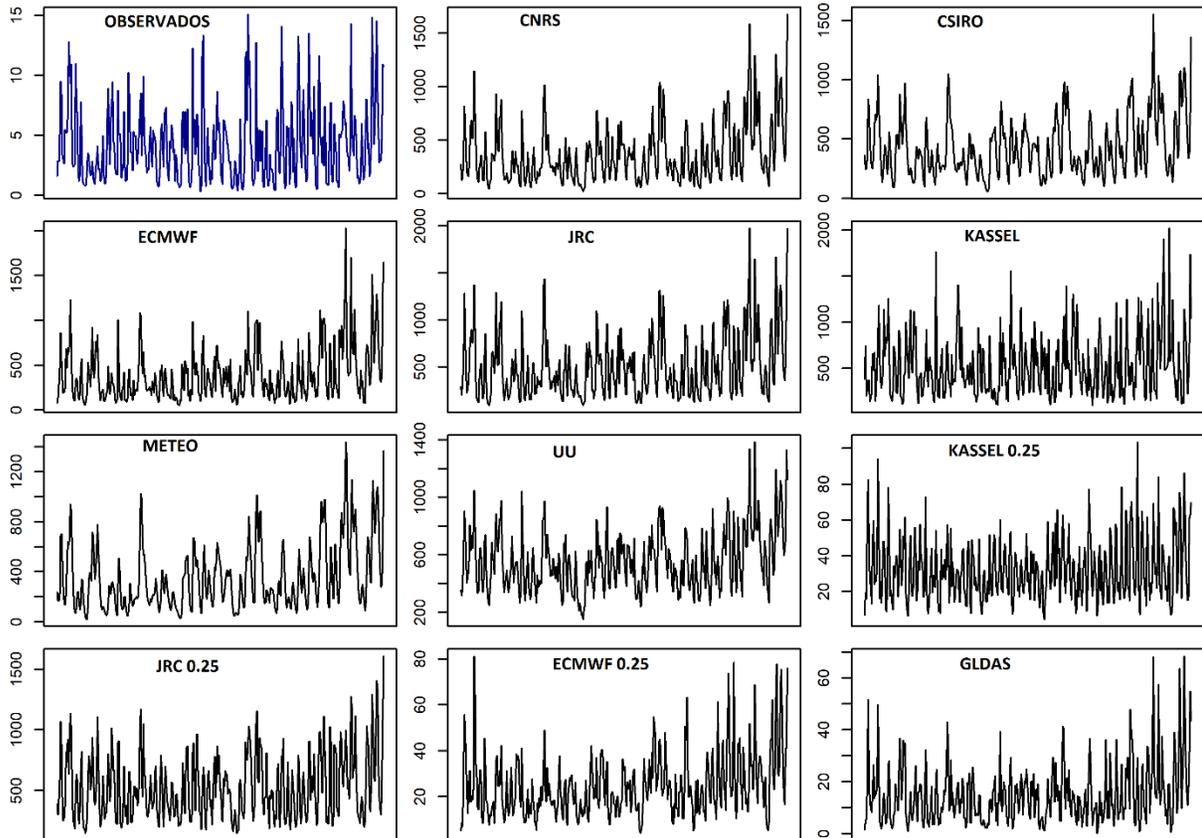
Fuente: Elaboración propia

Figura 13-6. Series de caudales modelos regionales y locales escala diaria cuenca Prado periodo de 1981-2002



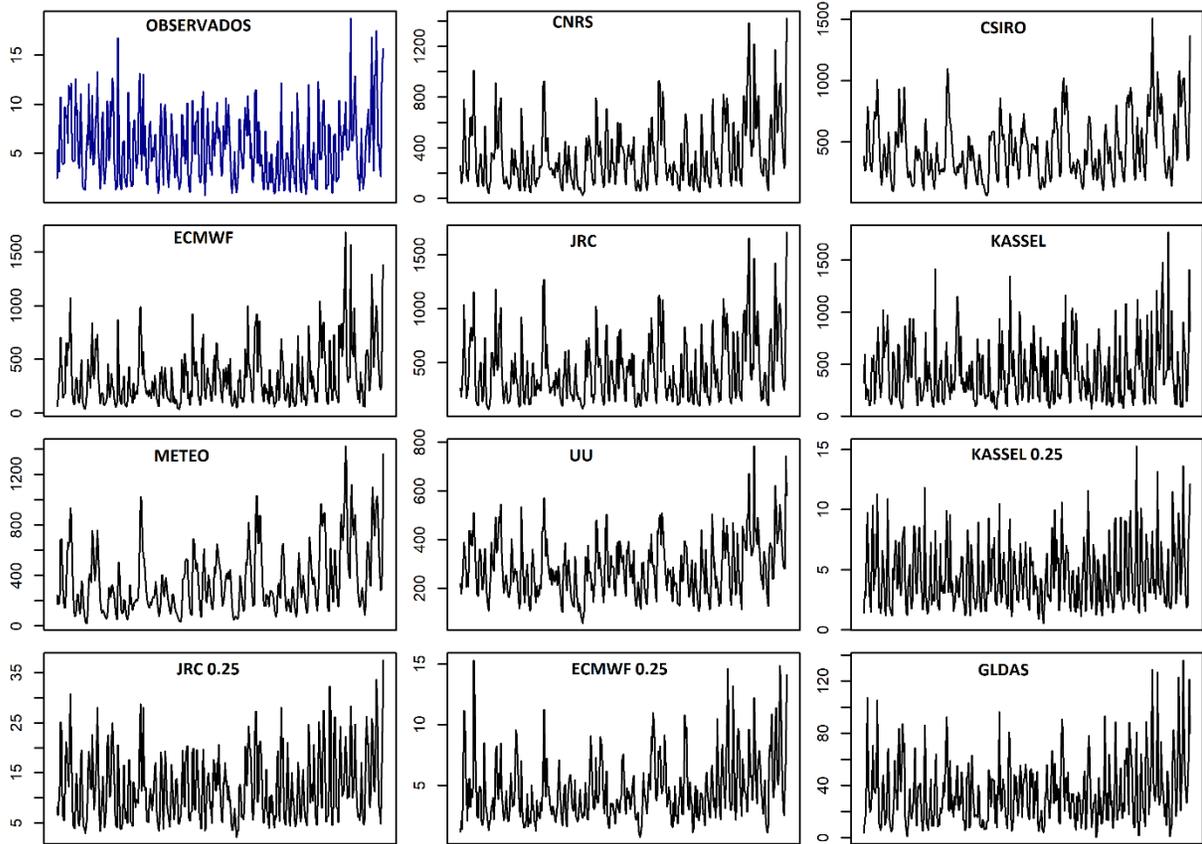
Fuente: Elaboración propia

Figura 13-7. Series de caudales de modelos globales escala mensual cuenca Cunday periodo 1981-2011



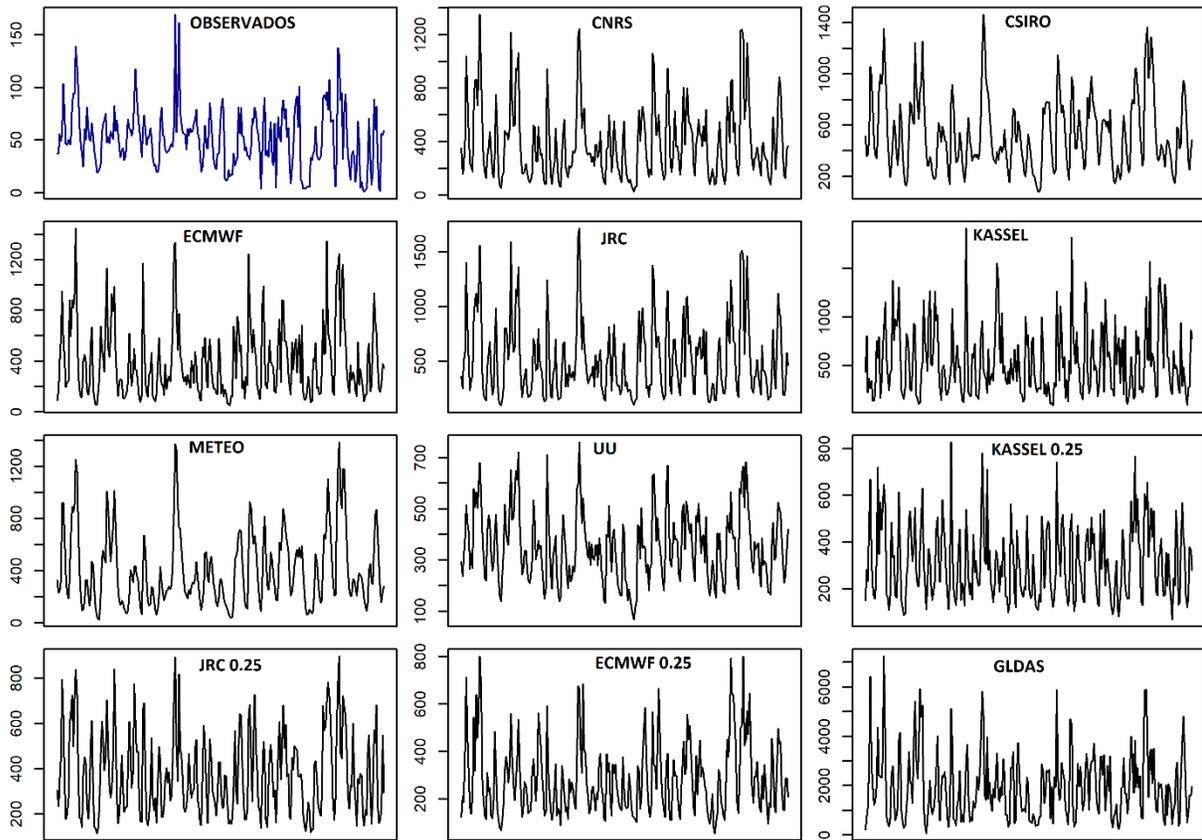
Fuente: Elaboración propia

Figura 13-8. Series de caudales modelos globales escala mensual cuenca San Pablo periodo 1981-2011



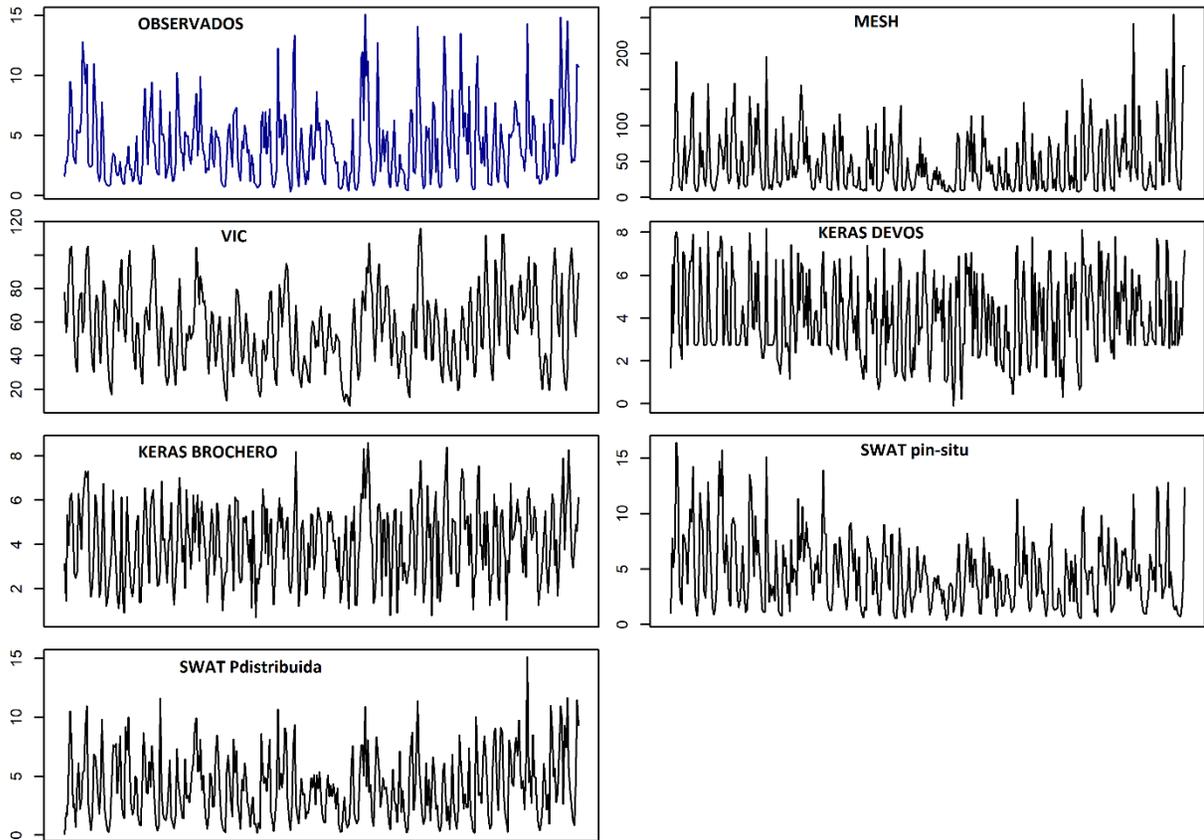
Fuente: Elaboración propia

Figura 13-9. Series de caudales modelos globales escala mensual cuenca Prado periodo 1981-2002



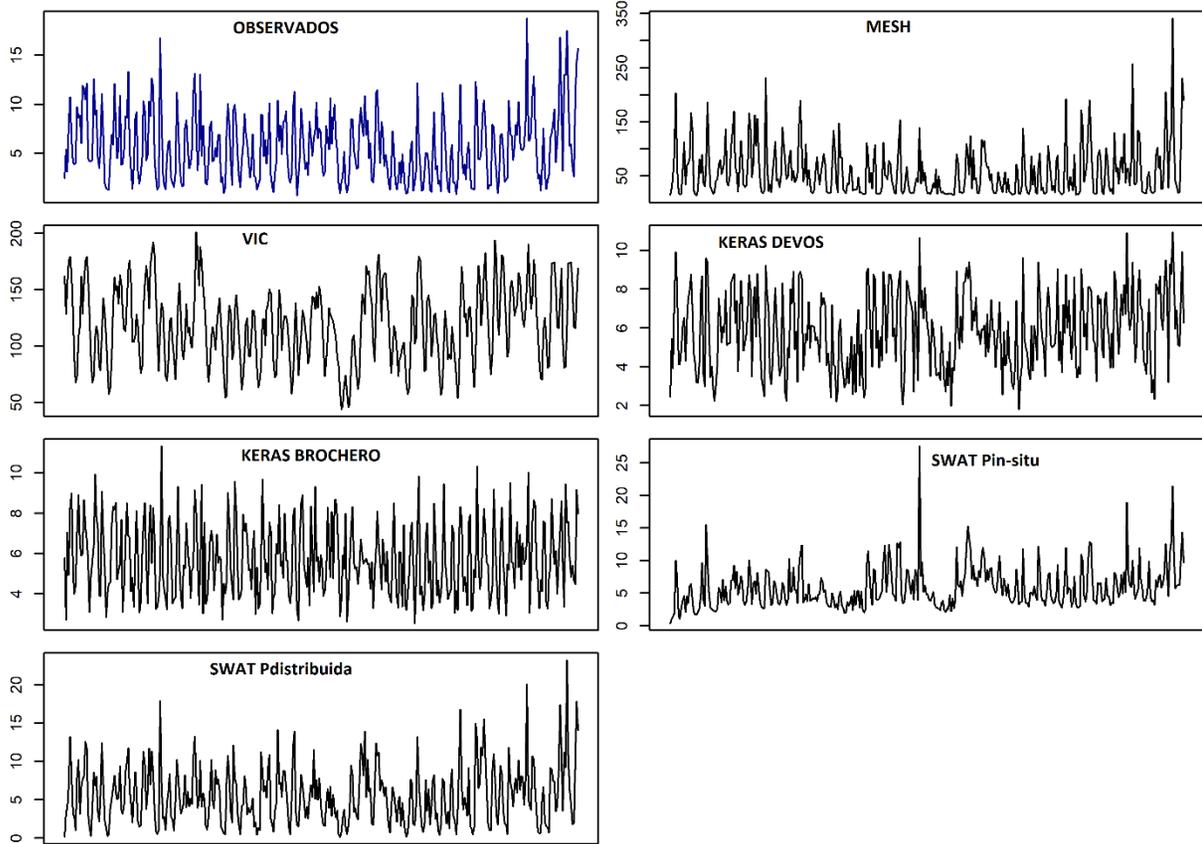
Fuente: Elaboración propia

Figura 13-10. Series de caudales de modelos regionales y locales escala mensual cuenca Cunday periodo 1981-2011



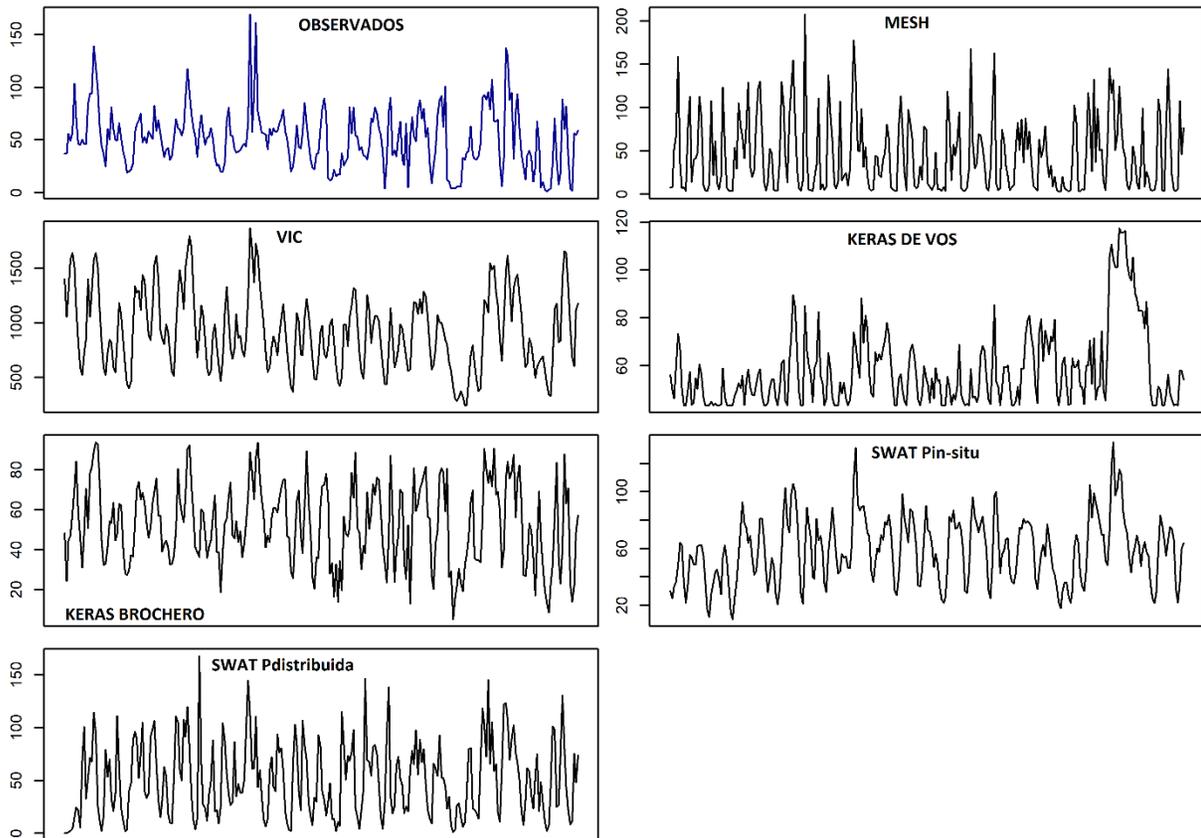
Fuente: Elaboración propia

Figura 13-11. Series de caudales modelos regionales y locales escala mensual cuenca San Pablo periodo 1981-2011



Fuente: Elaboración propia

Figura 13-12. Series de caudales modelos regionales y locales escala mensual cuenca Prado periodo 1981-2002



Fuente: Elaboración propia

14. ANEXO 3. HIDRÓGRAFA DE NME ESCALA DIARIA Y MENSUAL

Series de caudales observados y los tres nuevos mejores ensambles NME escala diaria.

Figura 14-1. Observados y nuevo mejor ensamble (NME~KGE, NME~NSE y NME~CRPS) Cunday escala diaria -periodo de calibración 1981-2002

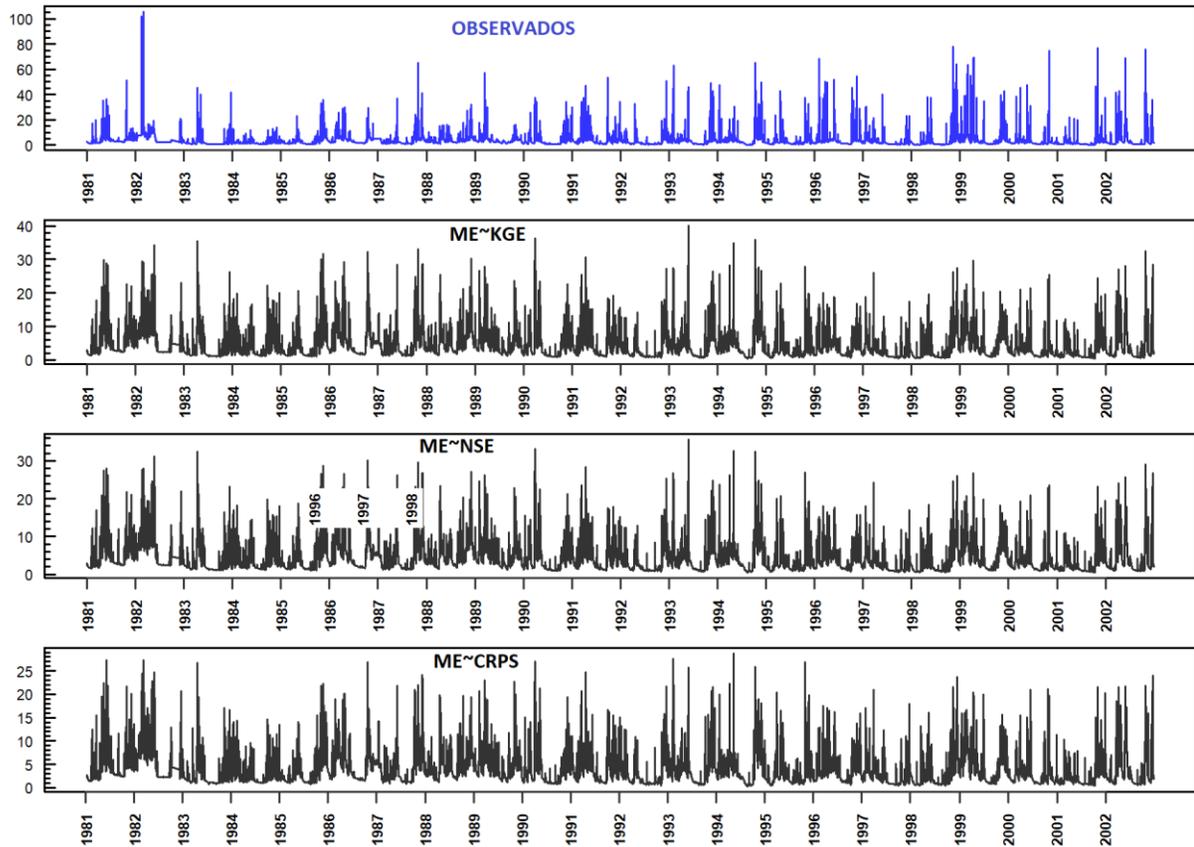


Figura 14-2 Observados y nuevo mejor ensamble (NME~KGE, NME~NSE y NME~CRPS) Cuenca San Pablo escala diaria periodo de calibración 1981-2002

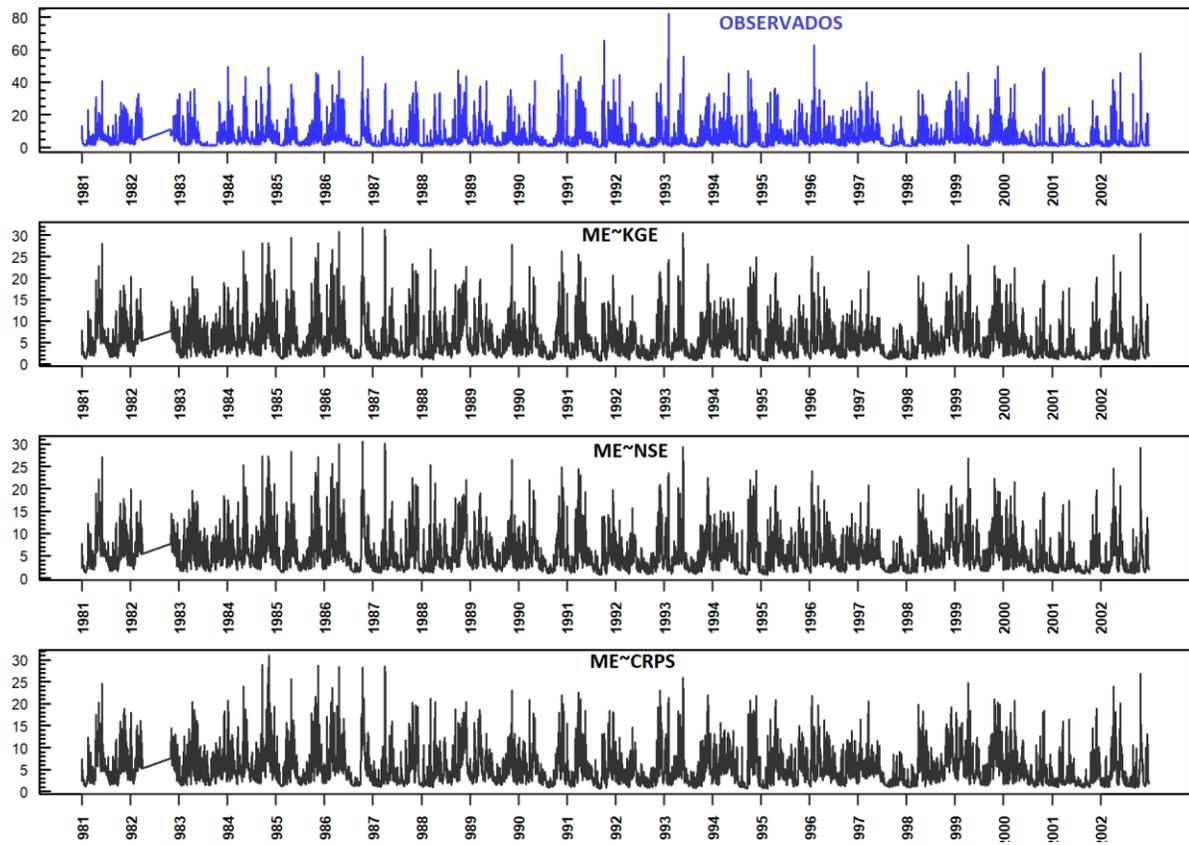
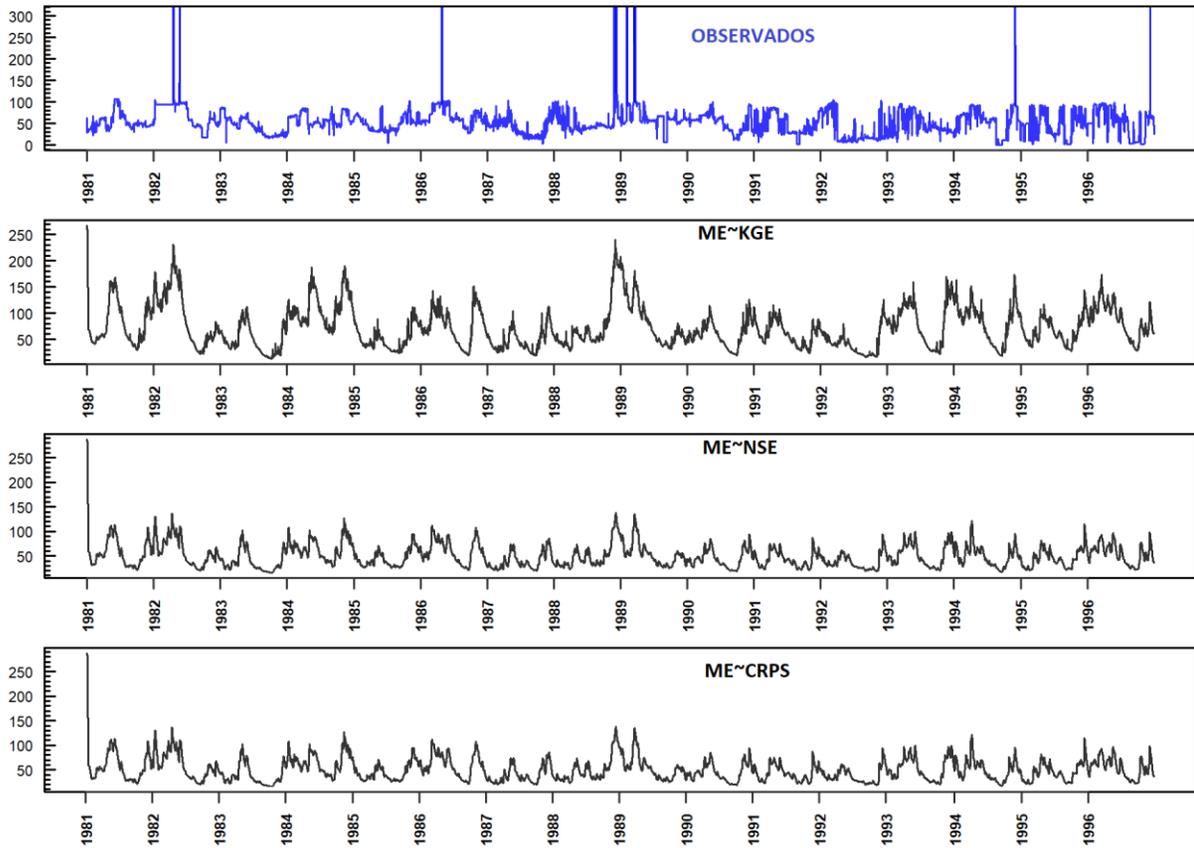


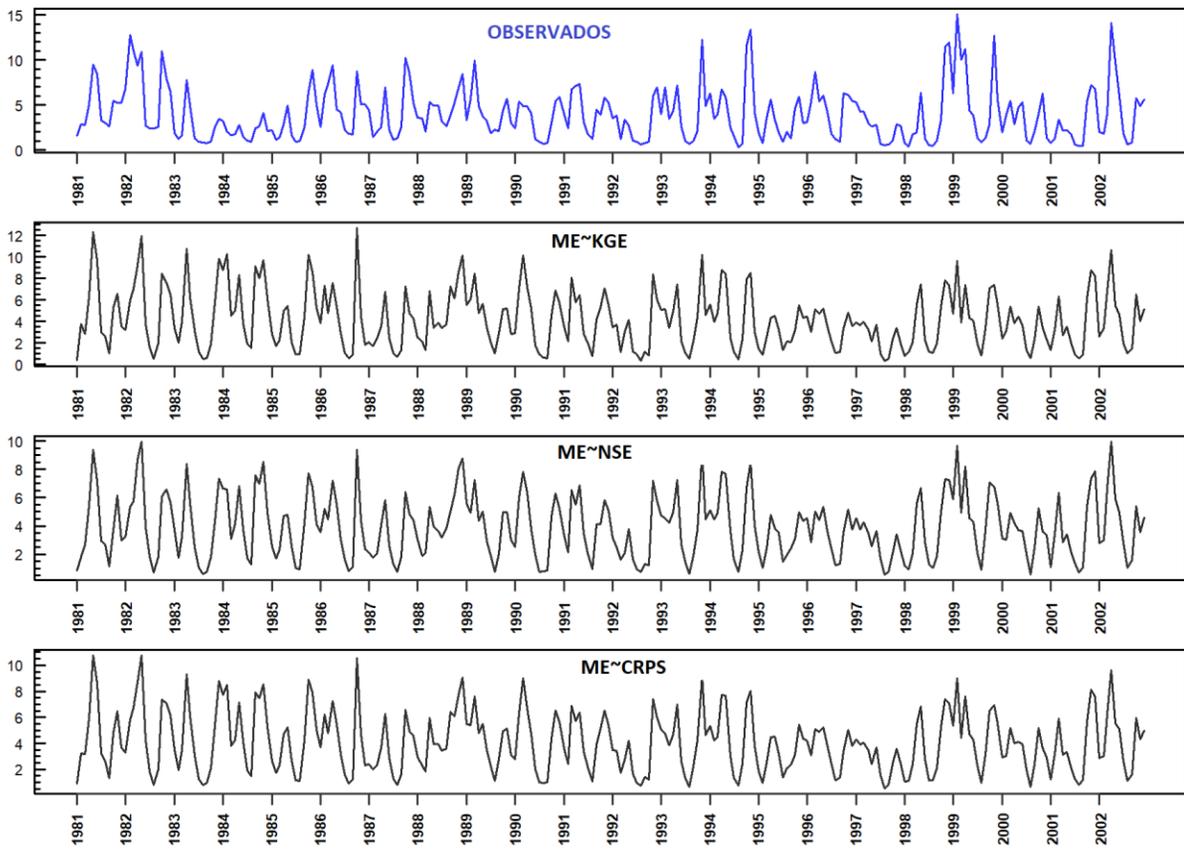
Figura 14-3. Observados y nuevo mejor ensamble (NME~KGE, NME~NSE y NME~CRPS) Cuenca Prado escala diaria periodo de calibración 1981-1996



Fuente: Elaboración propia

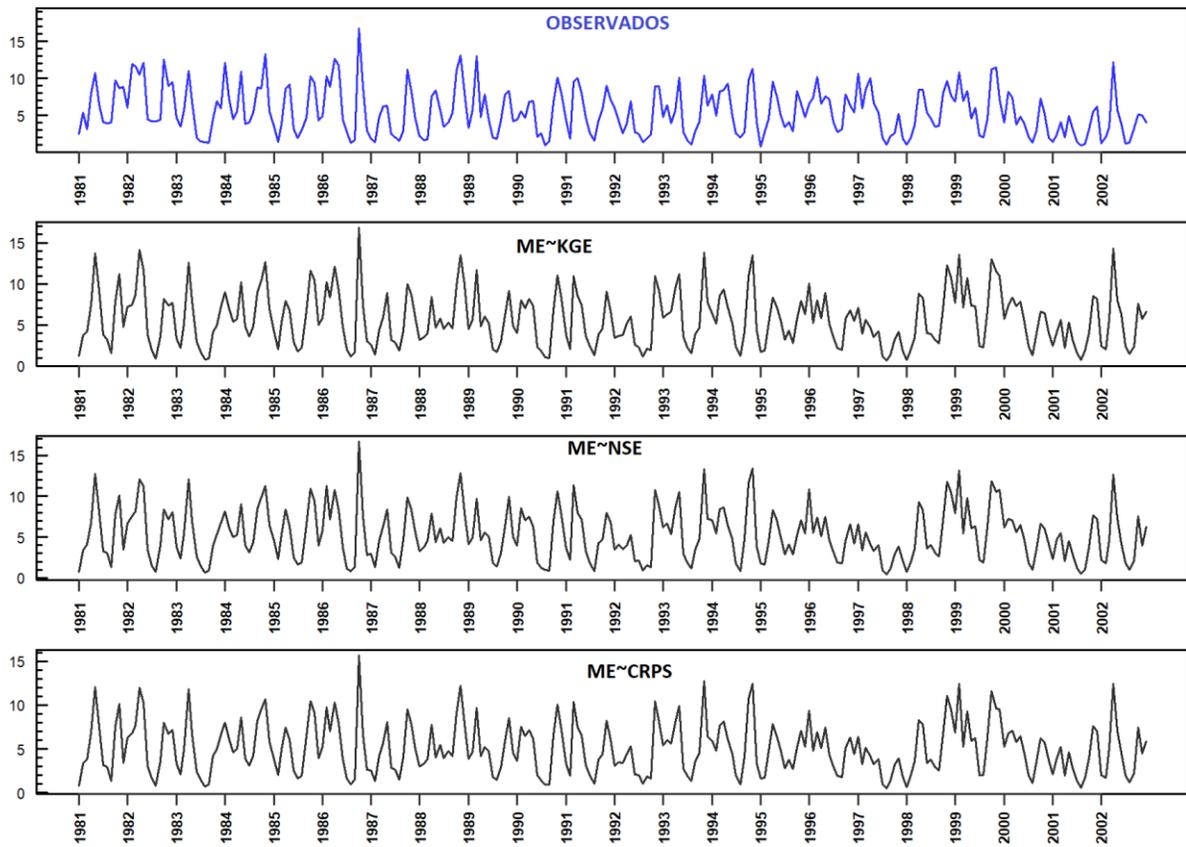
Series de caudales observados y los tres nuevos mejores ensambles NME escala mensual.

Figura 14-4. Observados y nuevo mejor ensamble (NME~KGE, NME~NSE y NME~CRPS) Cuenca Cunday escala mensual periodo de calibración 1981-2002



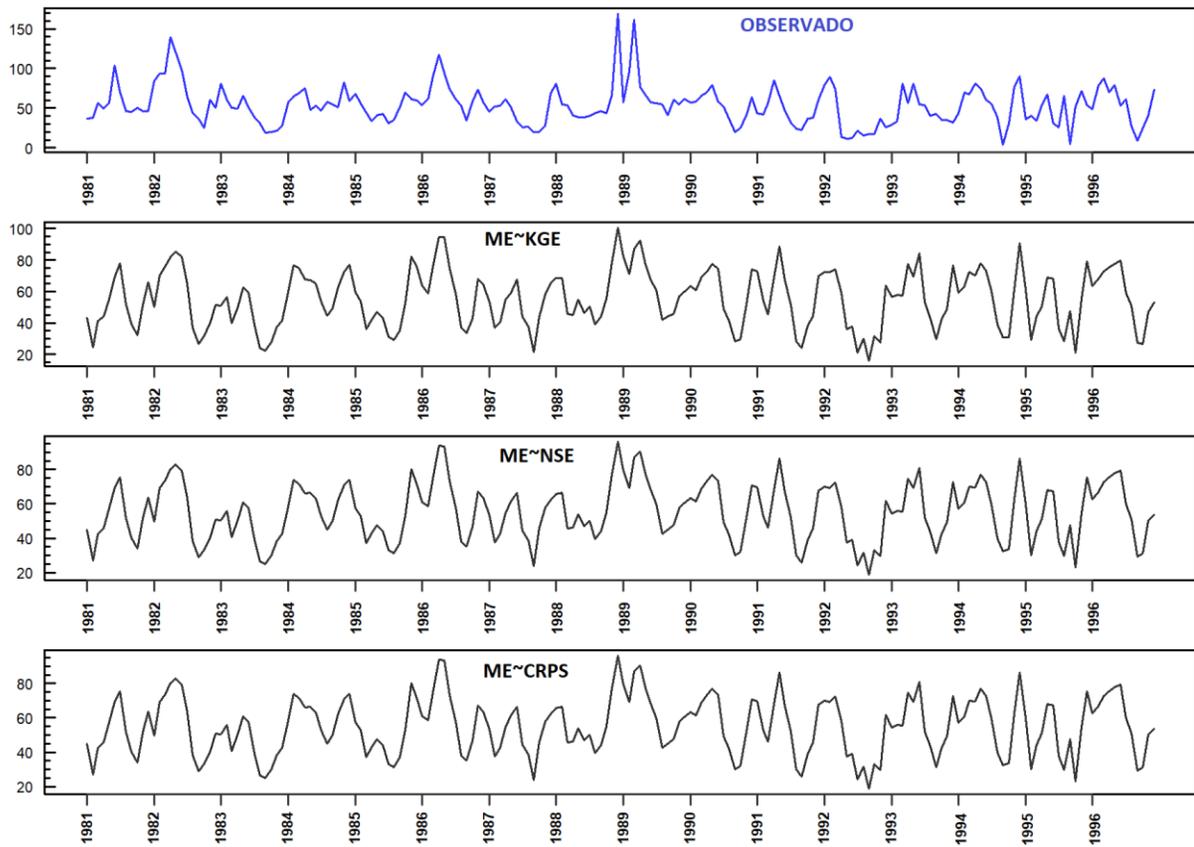
Fuente: Elaboración propia

Figura 14-5. Observados y nuevo mejor ensamble (NME~KGE, NME~NSE y NME~CRPS) Cuenca San Pablo escala mensual periodo de calibración 1981-2002



Fuente: Elaboración propia

Figura 14-6. Observados y nuevo mejor ensamble (NME~KGE, NME~NSE y NME~CRPS) Cuenca Prado escala mensual periodo de calibración 1981-1996



Fuente: Elaboración propia