



Universitat Politècnica de València
Departamento de Ingeniería Hidráulica y Medio Ambiente
Programa de Doctorado en Ingeniería del Agua y Medioambiental

Improving hydrological post-processing for assessing the conditional predictive uncertainty of monthly streamflow

Autor: Jonathan Romero Cuéllar
Supervisor: Félix Francés García



GOBERNACION DEL HUILA



COLCIENCIAS



COLFUTURO



Instituto de Ingeniería del
Agua y Medio Ambiente

Noviembre, 2019



Índice de contenidos

1. Marco conceptual
2. Objetivos de la Tesis
3. El problema de la heterocedasticidad
4. El problema de la verosimilitud intratable
5. Aplicación del Post-procesador ABC a las proyecciones de Cambio Climático
6. Conclusiones
7. Futuras líneas de investigación

1. Marco conceptual

'We build too many walls and not enough bridges'

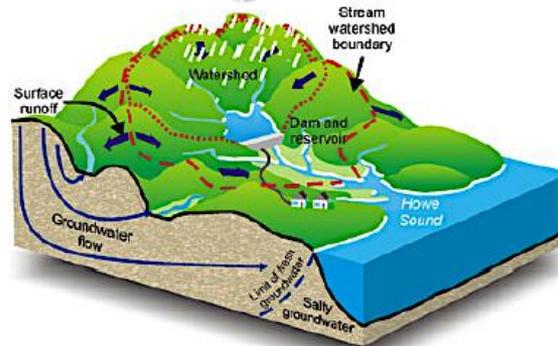
-Issac Newton-



Motivación

- ▶ El santo grial de la hidrología es incrementar la capacidad de **entendimiento** y **predicción** hidrológica (Gupta et al., 2014)
- ▶ Sin embargo, las **predicciones** hidrológicas **fiables** son un desafío debido a que padecen de varias **fuentes de incertidumbre** (Kuczera et al. 2006 y muchos otros)

Sistema Complejo



Incertidumbre de los datos

- Baja densidad de estaciones
- Alta variabilidad en espacio y tiempo
- Errores en la información espacial
- Errores de muestreo: lluvia y caudal
- Errores en la curva de gasto
- Condiciones iniciales

Incertidumbre estructural

- Conceptualización de los procesos
- Selección de variables
- Resolución espacial y temporal
- Solución numérica

Incertidumbre de los parámetros

- Equifinalidad
- Diferentes algoritmos de optimización
- Métodos Bayesianos
- Máxima verosimilitud

Predicciones hidrológicas inciertas



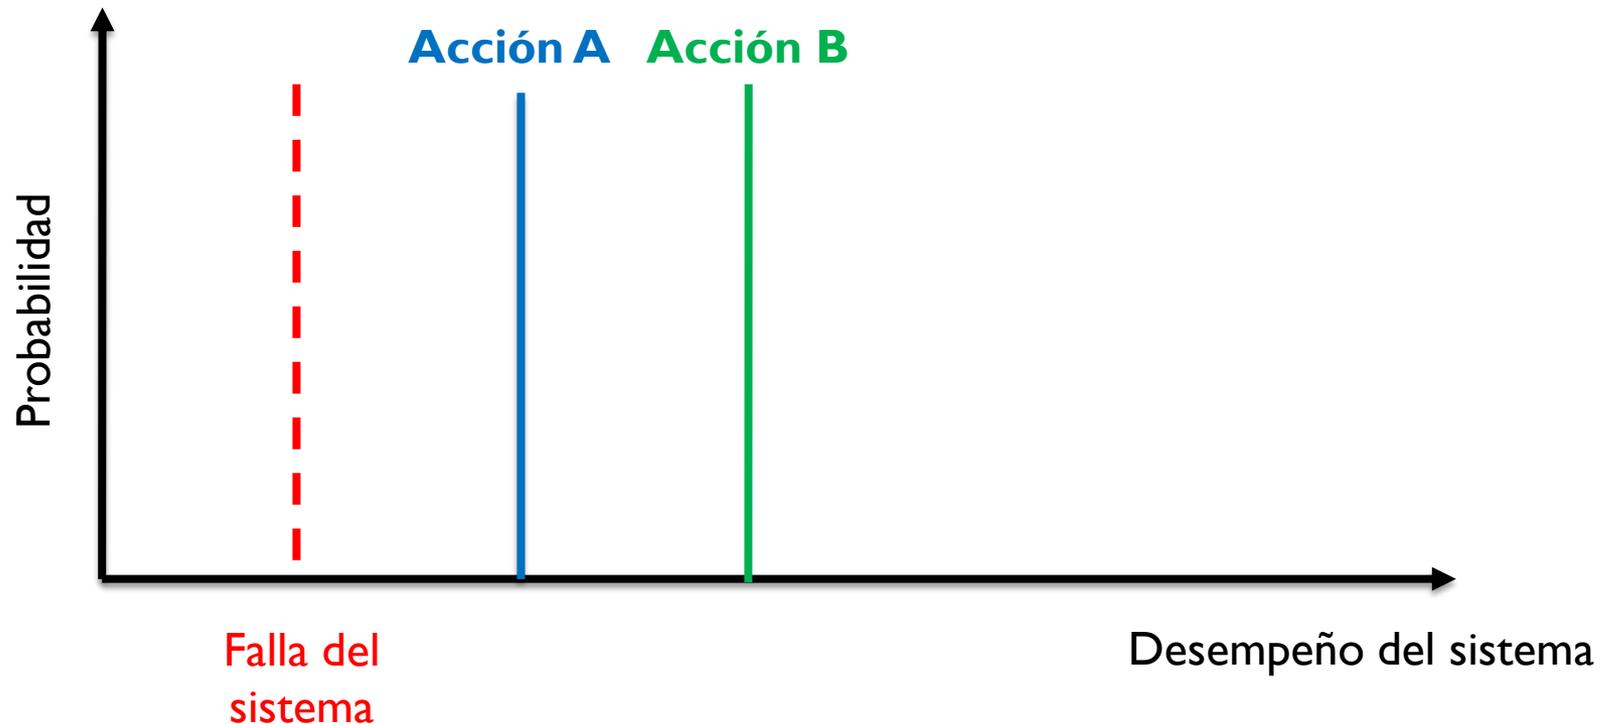
Motivación

- ▶ Uno de los desafíos más importantes de la hidrología es incrementar la capacidad de entendimiento y predicción hidrológica (Gupta et al., 2014)
- ▶ Sin embargo, las predicciones hidrológicas fiables son un desafío debido a varias fuentes de incertidumbre (Kuczera et al., 2006 y muchos otros)
- ▶ La cuantificación de la **incertidumbre predictiva** es fundamental para apoyar la **toma de decisiones** de manera informada (Krzysztofowicz y Kelly, 2000)



Toma de decisiones de manera informada

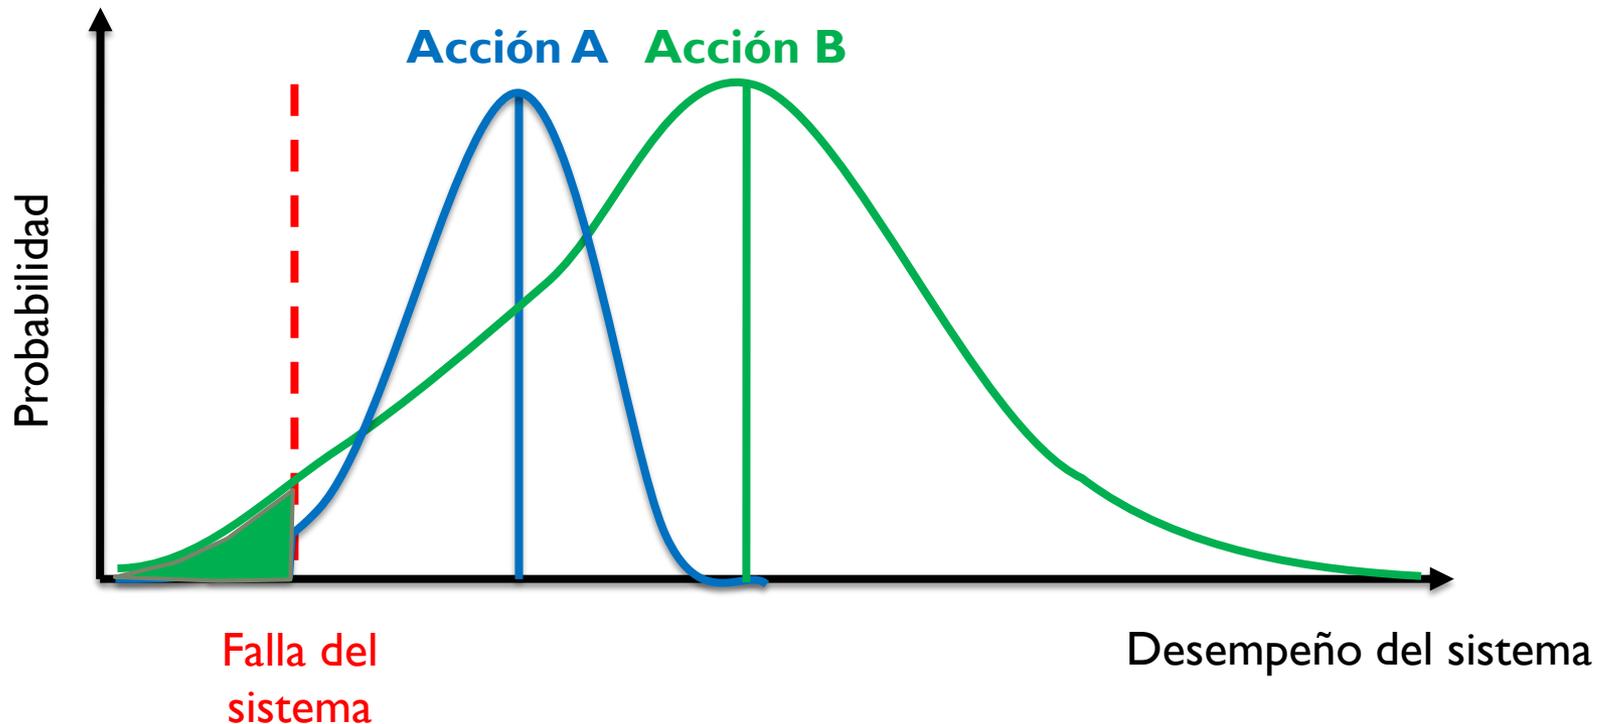
- ▶ Consecuencias de la **acción A** versus la **acción B**
- ▶ Seleccionando el resultado de mejor desempeño → Se escoge la **acción B**





Toma de decisiones de manera informada

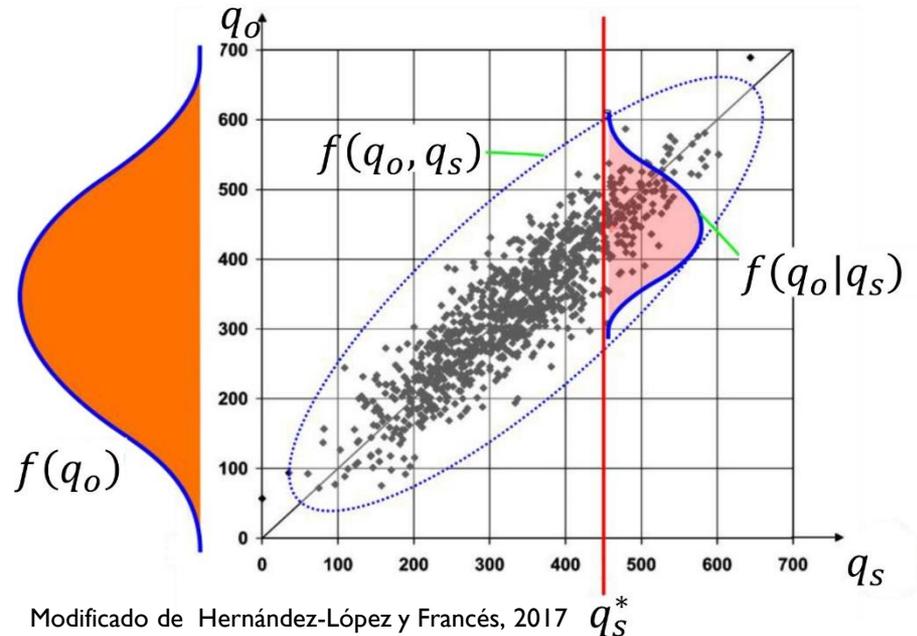
- ▶ Consecuencias de la **acción A** versus la **acción B**
 - ▶ Seleccionando el resultado de mejor desempeño → Se escoge la **acción B**
- ▶ Incluyendo el análisis de incertidumbre se presentan nuevas evidencias:
 - ▶ En promedio la **acción B** produce mejores resultados pero es más incierta





Incertidumbre predictiva

La incertidumbre predictiva describe la **probabilidad** de ocurrencia de una **observación** futura **condicionado** a toda la información y el conocimiento disponible (**predicciones**) en el presente (Krzysztofowicz, 1999; Todini, 2008; Biondi and Todini, 2018)





Post-procesamiento hidrológico

- ▶ El **post-procesamiento** hidrológico es una técnica **estadística** que se utiliza para:
 - ▶ **Caracterizar la incertidumbre y eliminar el sesgo** de las predicciones hidrológicas (Hopson et al., 2019)
 - ▶ Mejorar las predicciones puntuales (deterministas) estableciendo la relación entre las predicciones y las observaciones (Ye et al., 2014)
 - ▶ Diluir los errores de todas las fuentes de incertidumbre (Buizza, 2018; Ye et al., 2014)

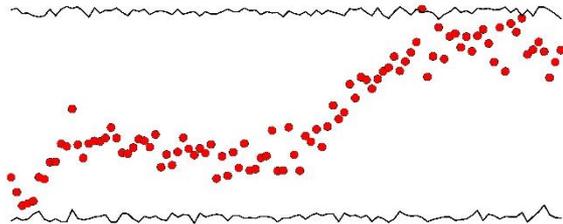
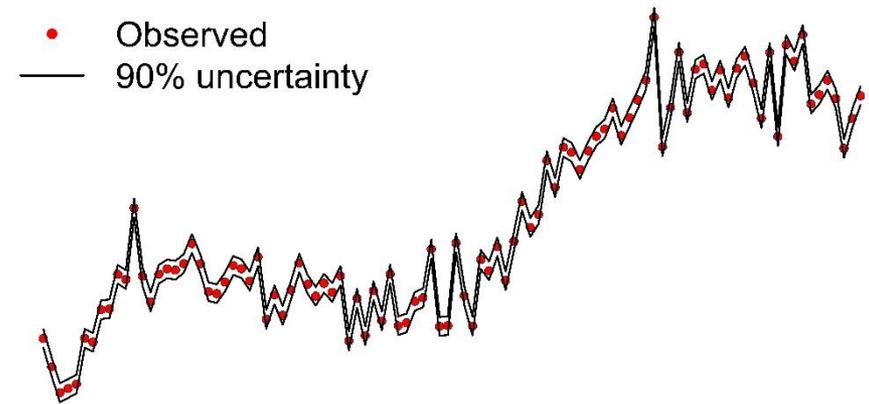


Métricas de desempeño

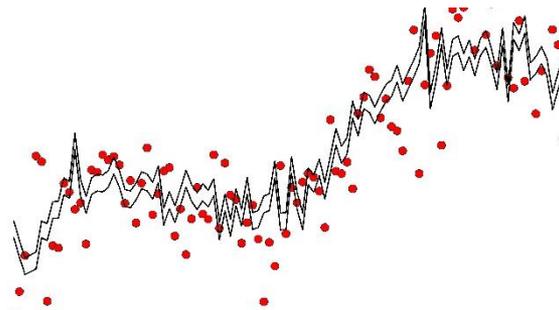
Se buscan predicciones que sean:

- ▶ **Fiables:** Predicciones estadísticamente consistente con las observaciones
- ▶ **Precisas:** Incertidumbre pequeña en las predicciones
- ▶ **Exactas:** Predicciones que no muestran una tendencia errónea

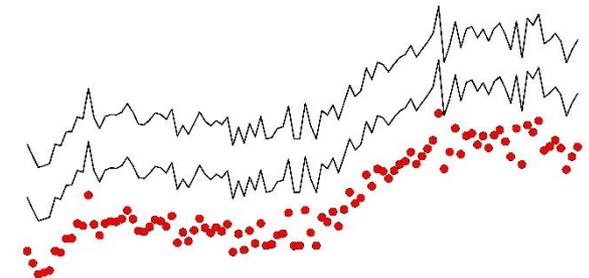
Fiables, precisas y exactas



Fiables pero imprecisas



Precisas pero poco fiables



Inexactas



Métricas de desempeño

Se utilizaron las métricas de desempeño recomendadas por Laio y Tamea (2007), Renard et al. (2010), Thyer et al. (2009):

$$NSE = 1 - \frac{\sum_{i=1}^n (q_s - q_o)^2}{\sum_{i=1}^n (q_o - \bar{q}_o)^2} \quad \text{Deterministas}$$

$$KGE = 1 - \sqrt{(\rho - 1)^2 + (\beta - 1)^2 + (\gamma - 1)^2}$$

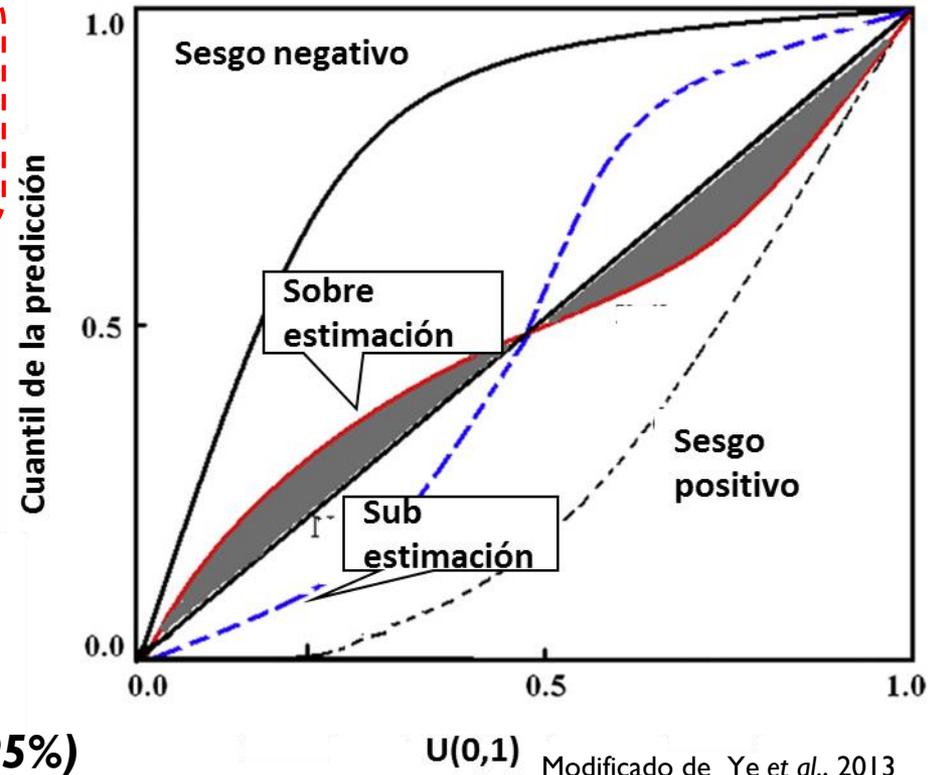
$$Fiabilidad = \frac{2}{n} \sum_{i=1}^n |F_U - F_{q_s}(q_o)|$$

$$Precisión = \frac{1}{n} \sum_{i=1}^n \frac{E[q_s]}{\sigma[q_s]}$$

$$d - factor = \frac{\frac{1}{n} \sum_{i=1}^n (Q_{up} - Q_{low})}{\sigma_{q_o}}$$

CR (95%)

QQPLOT



2. Objetivos de la Tesis

*'The biggest communication problem is that we listen to
reply, not to understand'*
-Stephen R. Covey-



Objetivos de la Tesis

- ▶ **Marco general:** Generar **predicciones** hidrológicas **fiables** utilizando **post-procesamiento** hidrológico para reducir el **sesgo** y cuantificar la **incertidumbre predictiva**
- ▶ **Objetivo general:** Mejorar los post-procesadores hidrológicos existentes en la estimación de la incertidumbre predictiva de los **caudales mensuales** (gestión recursos hídricos)
- ▶ Específicamente se abordaron dos temas i) el problema de la **heterocedasticidad** y ii) el problema de la **verosimilitud intratable**. Para superar estos problemas se proponen tres objetivos grandes:



Objetivos de la Tesis

► **Objetivos grandes:**

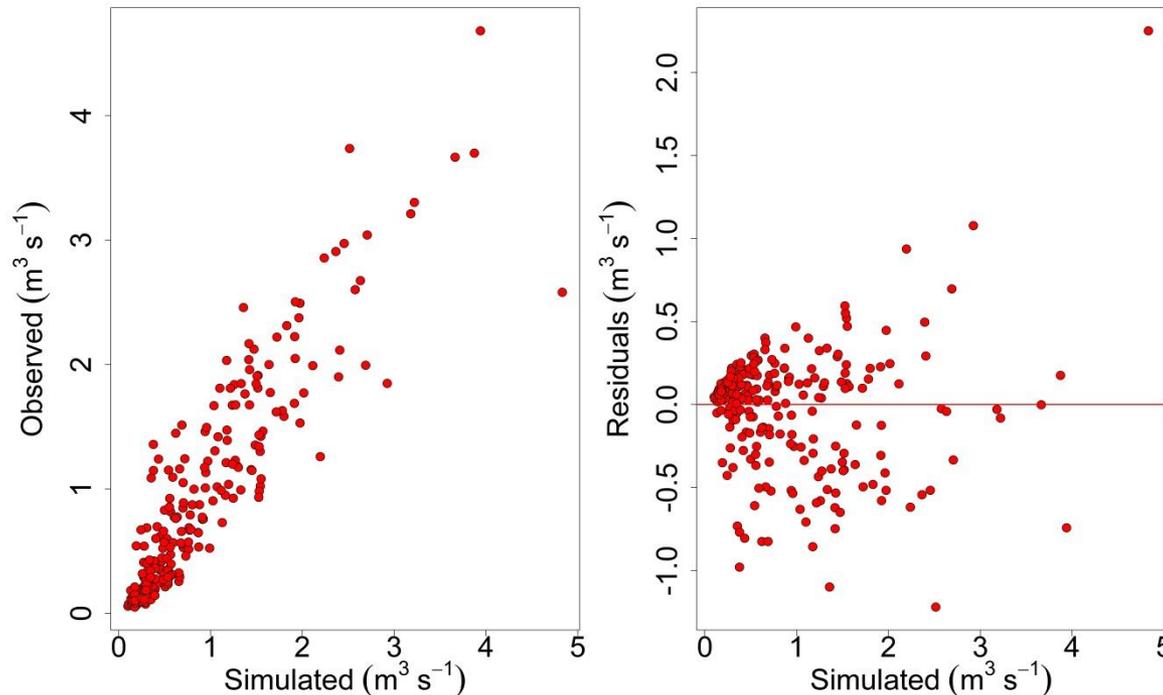
- 1) Desarrollar y evaluar un post-procesador hidrológico que aborde el problema de la heterocedasticidad de los caudales mensuales
- 2) Proponer un post-procesador hidrológico que afronte el problema de la función de verosimilitud intratable
- 3) Implementar el post-procesador ABC para cuantificar la incertidumbre predictiva de los estadísticos de las proyecciones de cambio climático

3. El problema de la heterocedasticidad

'You are not only responsible for what you say, but also for what you do not say'
-Martin Luther-

Heterocedasticidad

- ▶ Hetero (diferente) + cedasticidad (dispersión)
- ▶ La heterocedasticidad se presenta cuando la varianza de la variable dependiente condicional a la variable independiente no es constante a lo largo de toda la muestra



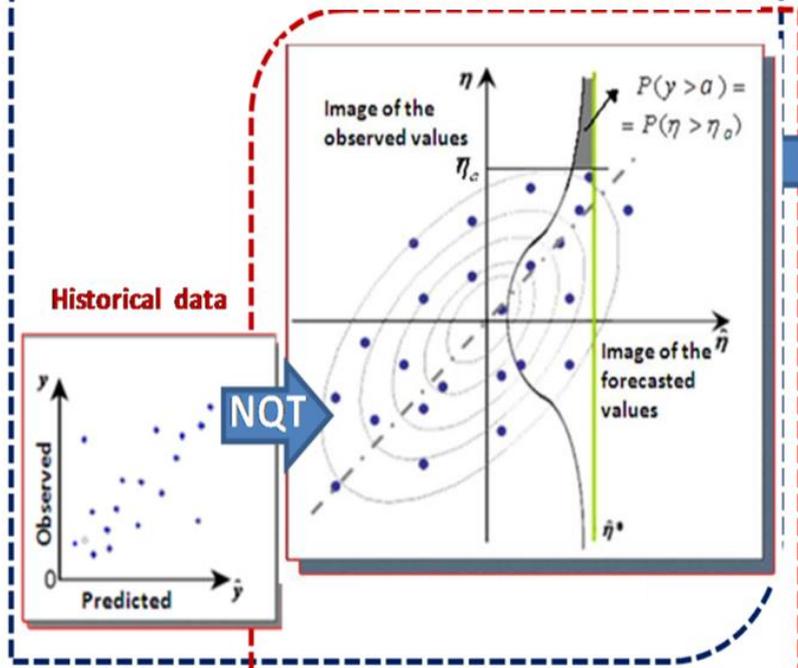


Objetivos específicos

- ▶ Desarrollar un nuevo post-procesador hidrológico que aborde el problema de la heterocedasticidad combinando el esquema de probabilidad conjunta Bayesiano (**BJP**) y la mezcla de Gaussianas (**GMM**)
- ▶ Evaluar y comparar el desempeño del post-procesador propuesto, llamado **post-procesador GMM**, con el Model Conditional Processor (**MCP**), MCP usando la Normal truncada (**MCP_t**) y la regresión lineal usando Markov Chain Monte Carlo (**MCMC**) en 12 cuencas del proyecto MOPEX

Model Conditional Processor (MCP)

1) Transformación al espacio normal usando NQT

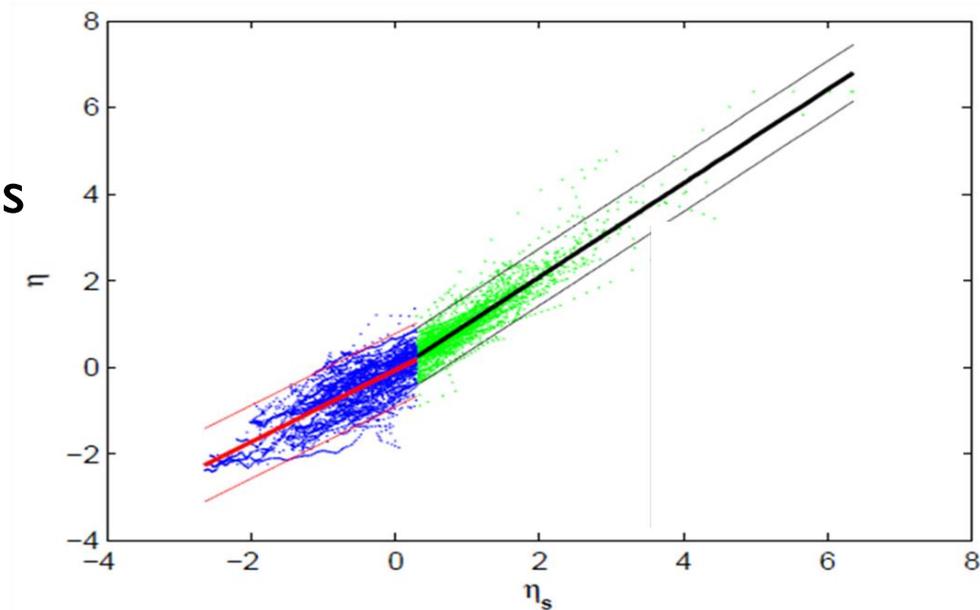




MCP usando la Normal truncada (MCPT)

► Problemas:

- El MCP tradicional asume que la **varianza** de los errores es **constante**
- El **coeficiente de correlación** no siempre representa bien los **caudales altos**



- Coccia and Todini (2011) modificaron el MCP tradicional separando el dominio de la distribución Normal en dos o más subgrupos donde se puede aplicar la distribución **Normal truncada**



Post-procesador de regresión lineal usando (MCMC)

- ▶ Modelo de regresión lineal:

$$y^o = \beta_0 + \beta_1 y^s + \varepsilon \quad \varepsilon \sim N(0, \sigma^2)$$

- ▶ MCMC produce muestras a partir de la distribución posterior de $\theta = (\beta_0, \beta_1, \sigma^2)$

$$p(\theta | y^o, y^s) = \frac{p(y^o | \theta, y^s) p(\theta)}{\int p(y^o | \theta, y^s) p(\theta) d\theta}$$

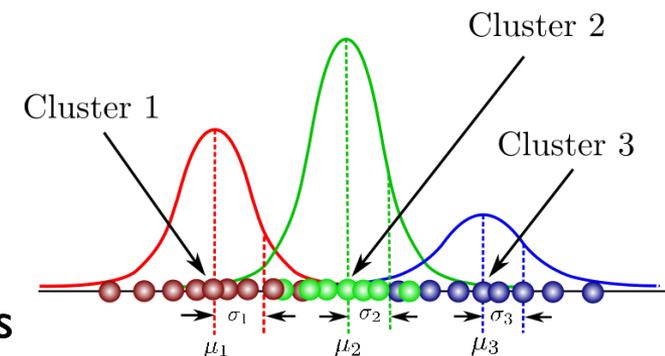
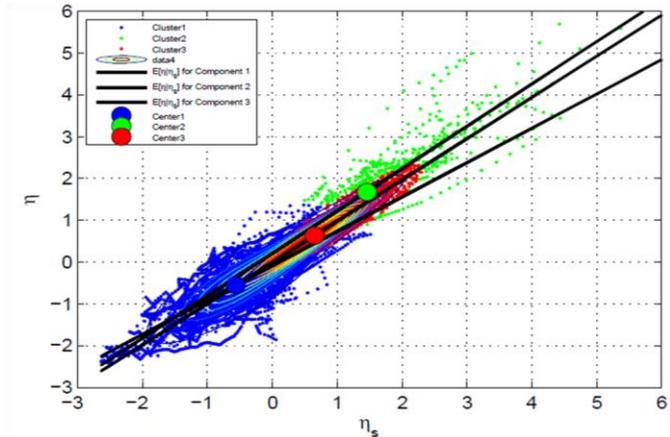
- ▶ Se utilizó el algoritmo adaptativo de Metropolis-Hastings Markov chain Monte Carlo (MCMC) (Haario et al., 2001)
- ▶ La distribución predictiva de una observación futura $p(\tilde{y}^o | y^s)$:

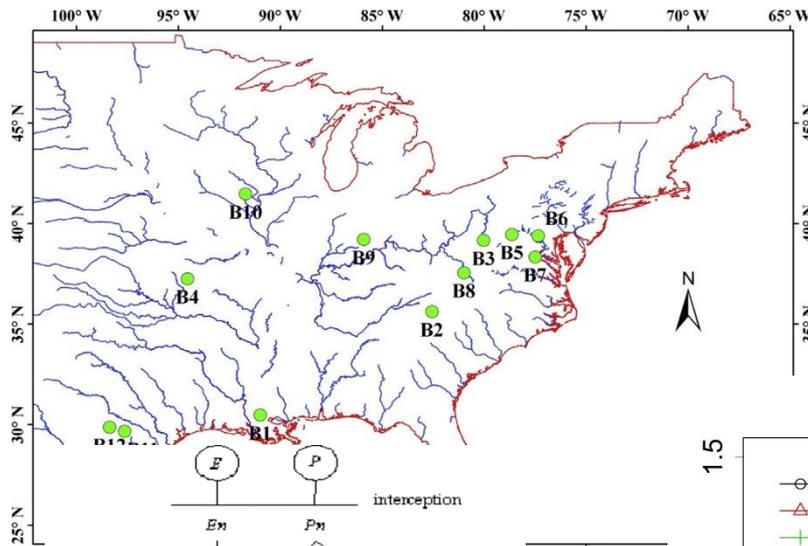
$$p(\tilde{y}^o | y^s) = \int_{\emptyset} p(\tilde{y}^o | \theta) p(\theta | y^o, y^s) d\theta$$

- ▶ GMM es un esquema **BJP** que se combina con la **mezcla de Gaussianas** para afrontar la heterocedasticidad
- ▶ GMM es un modelo **semiparamétrico guiado por datos**
- ▶ La mezcla de k Gaussianas (**clúster**) describen la distribución de una variable aleatoria Y

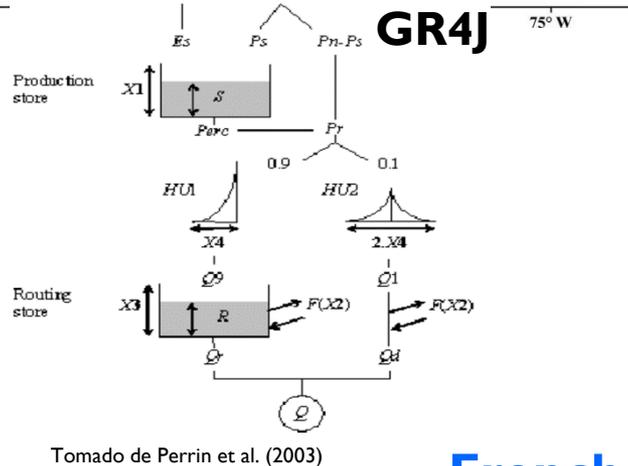
$$f(\mathbf{y}_j) = \sum_{i=1}^k \pi_i N_i(\mathbf{y}_j | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k); \quad \sum_{i=1}^k \pi_i = 1$$

Donde π_i son los **pesos**, $\boldsymbol{\mu}_k$ y $\boldsymbol{\Sigma}_k$ son el **vector** de las **medias** y la **matriz de covarianza** de k -th componente Gaussiano respectivamente

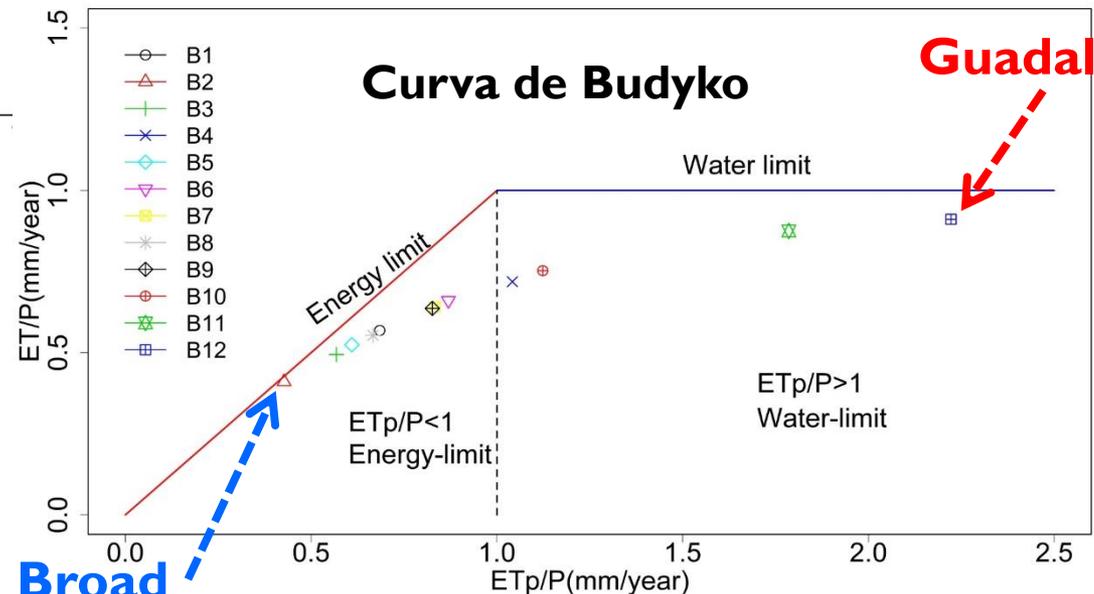




- 12 cuencas (contraste) con datos diarios:
- Observaciones
 - Simulaciones diferentes modelos hidrológicos (GR4J)

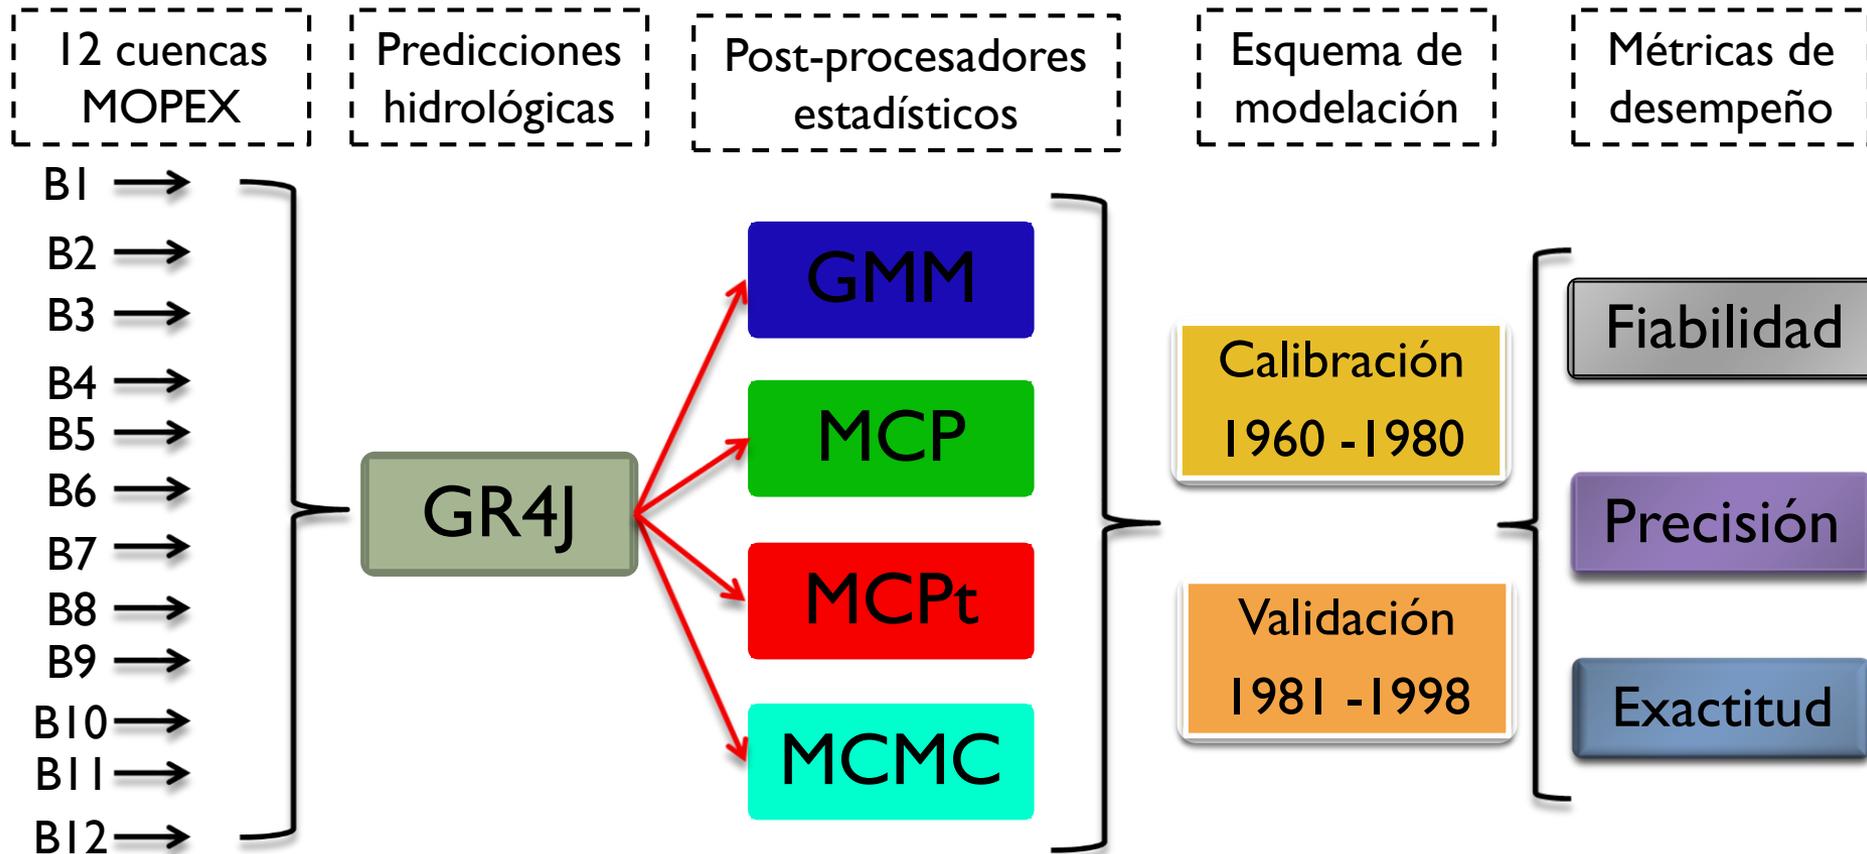


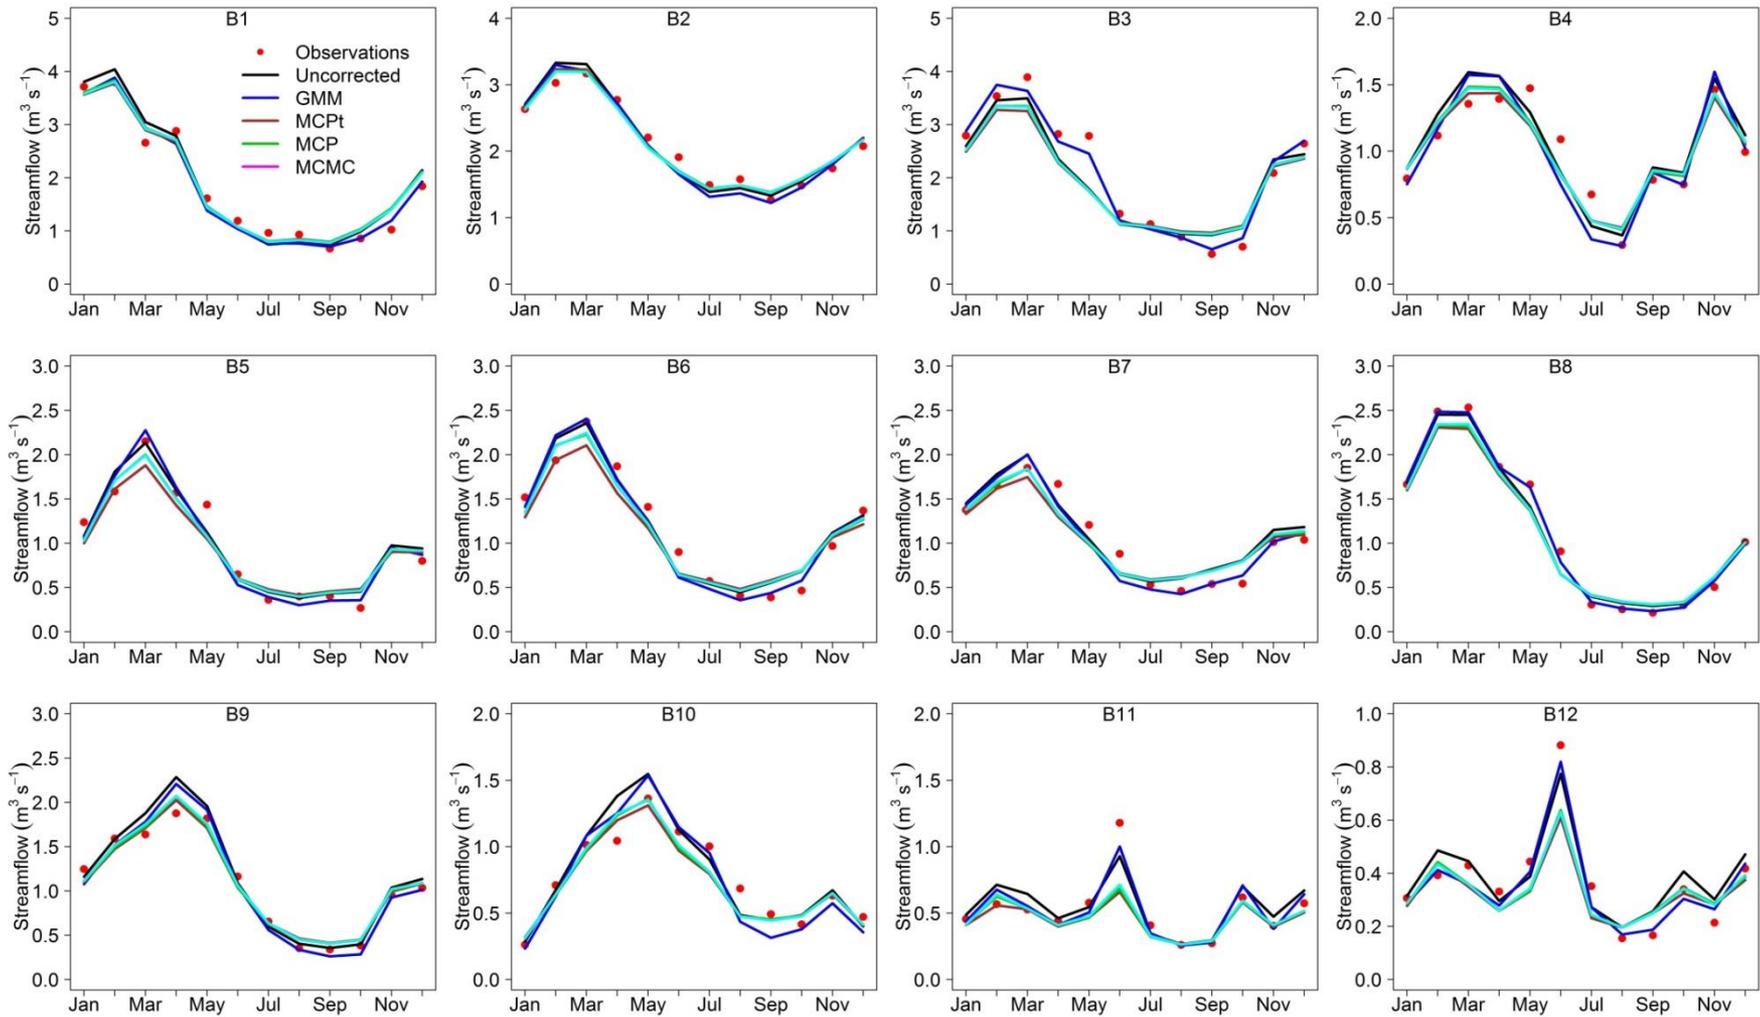
French Broad





Marco de comparación



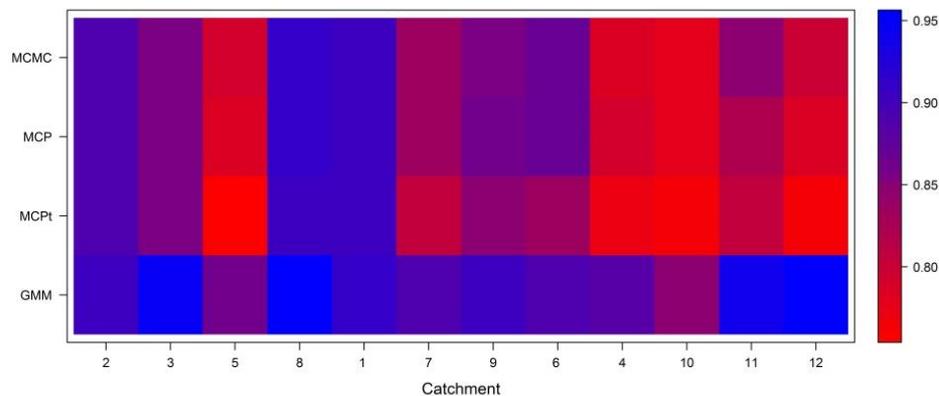


Caudales medios de las 12 cuencas del proyecto MOPEX durante el **período de validación** (1981-1998)

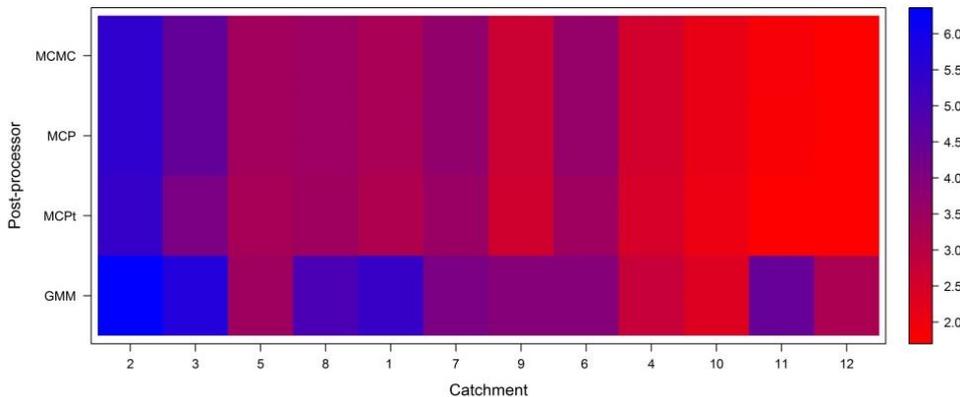


Métricas en período de validación

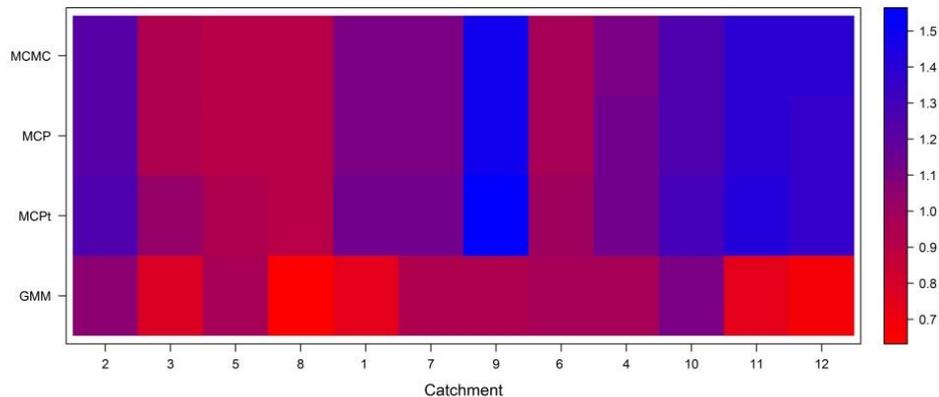
Nash-Sutcliffe efficiency (NSE)



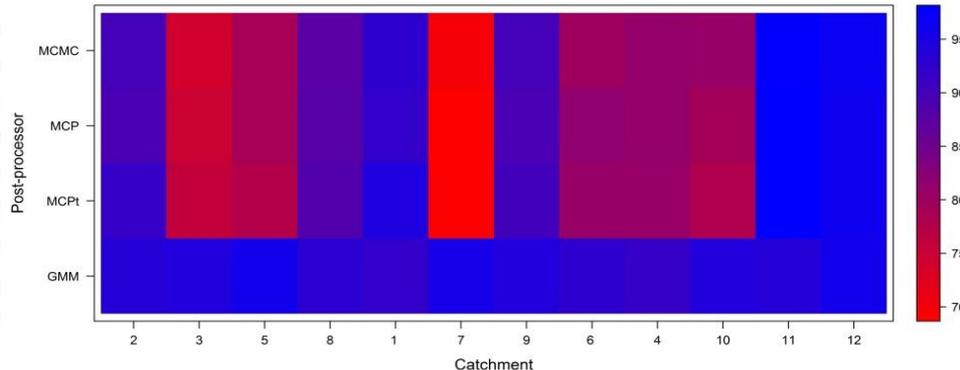
Precision



d-factor



CR (95%)

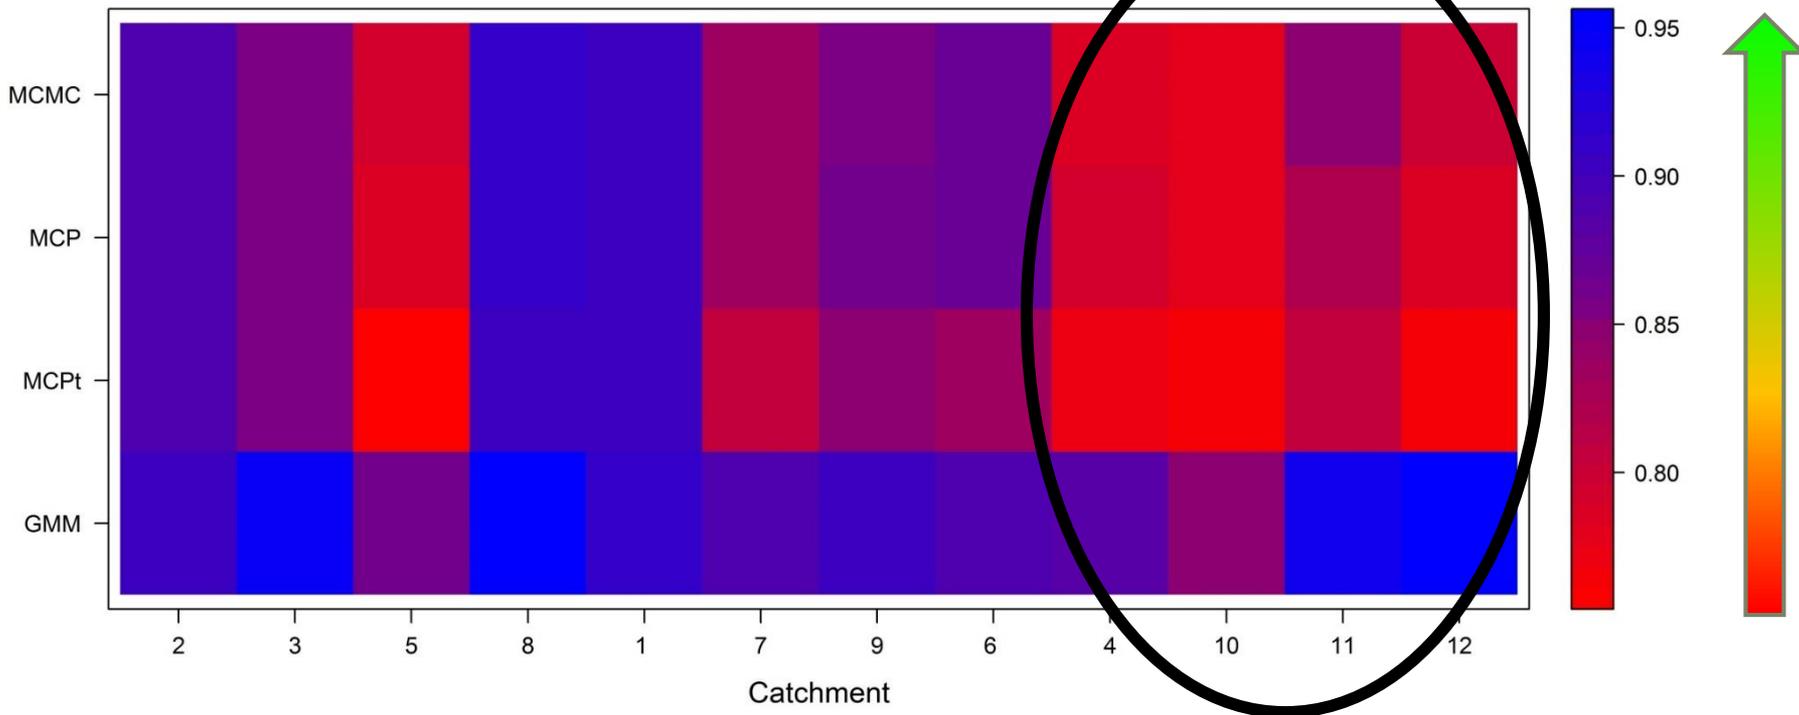


Métricas de desempeño para las 12 cuencas del proyecto MOPEX **ordenadas por el índice de aridez** durante el período de **validación** (1981-1998)



Métricas en período de validación

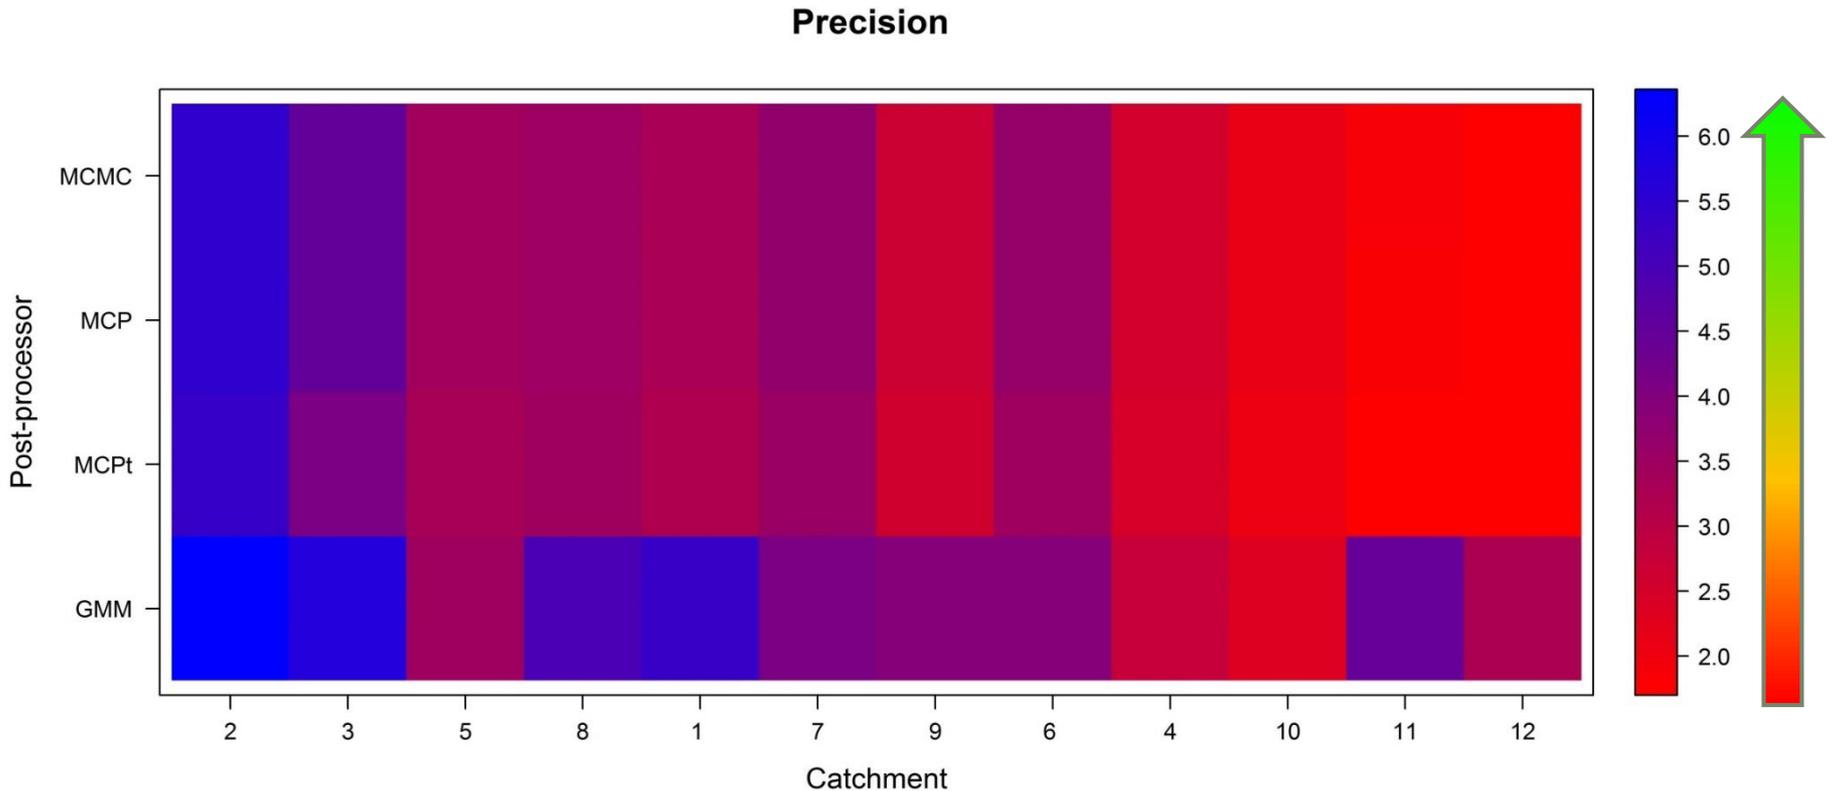
Nash-Sutcliffe efficiency (NSE)



Cuencas ordenadas de la más humedad a la más seca



Métricas en período de validación

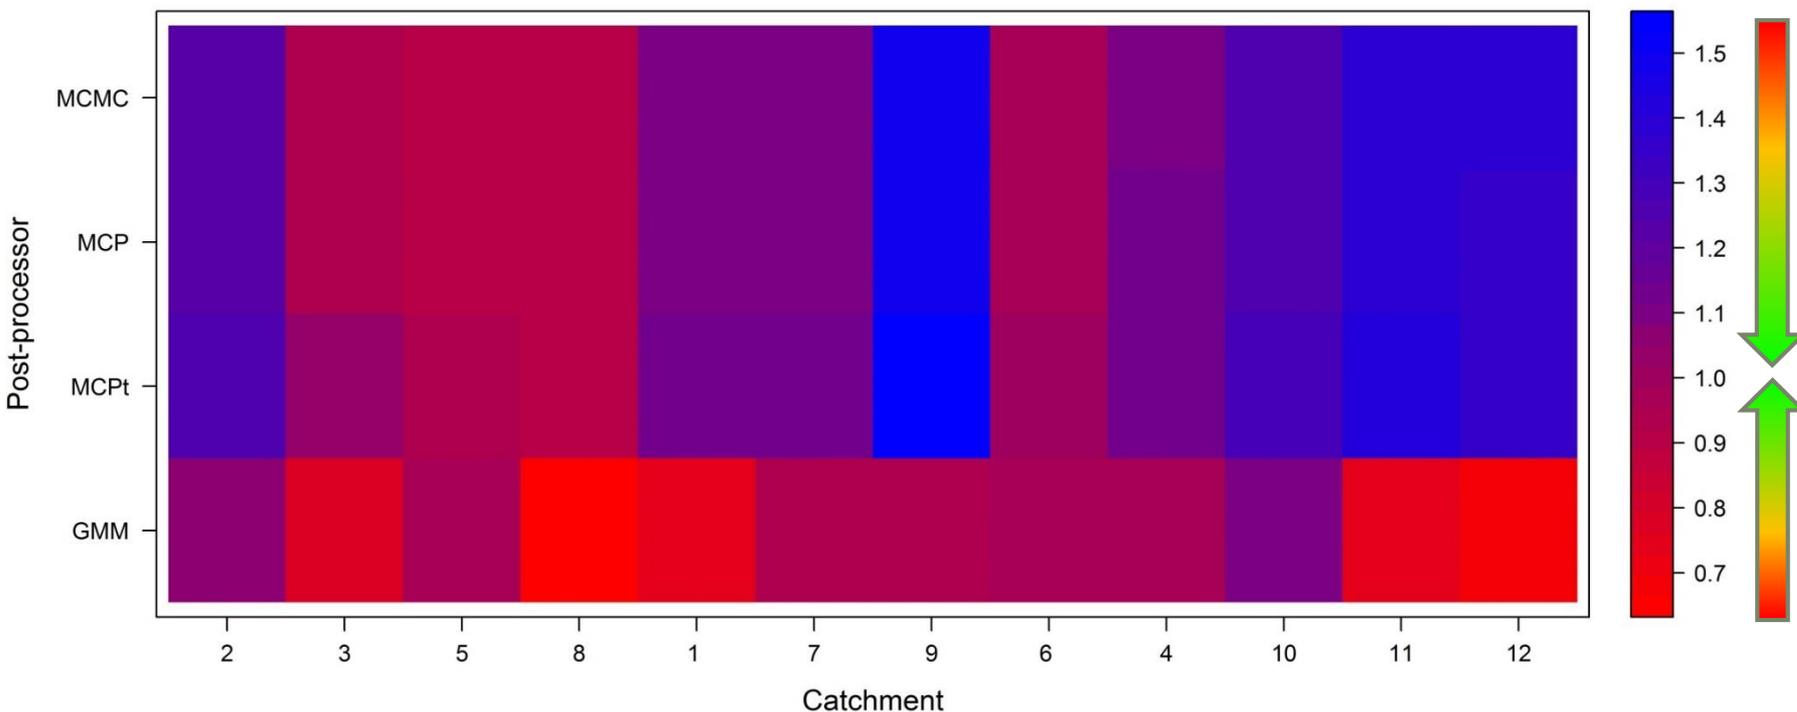


Cuencas ordenadas de la más humedad a la más seca



Métricas en período de validación

d-factor

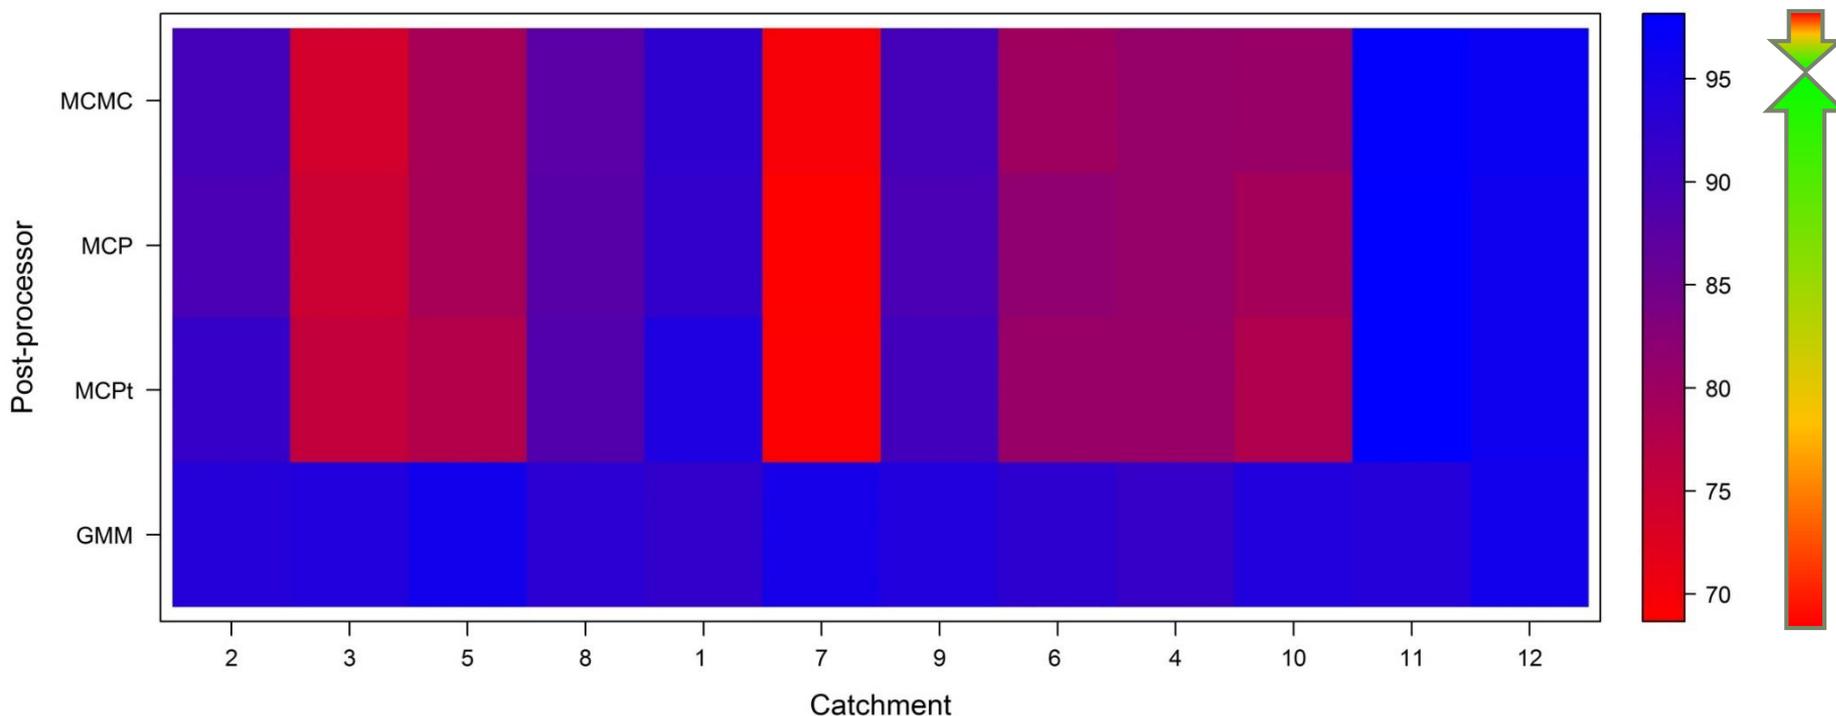


Cuencas ordenadas de la más humedad a la más seca



Métricas en período de validación

CR (95%)

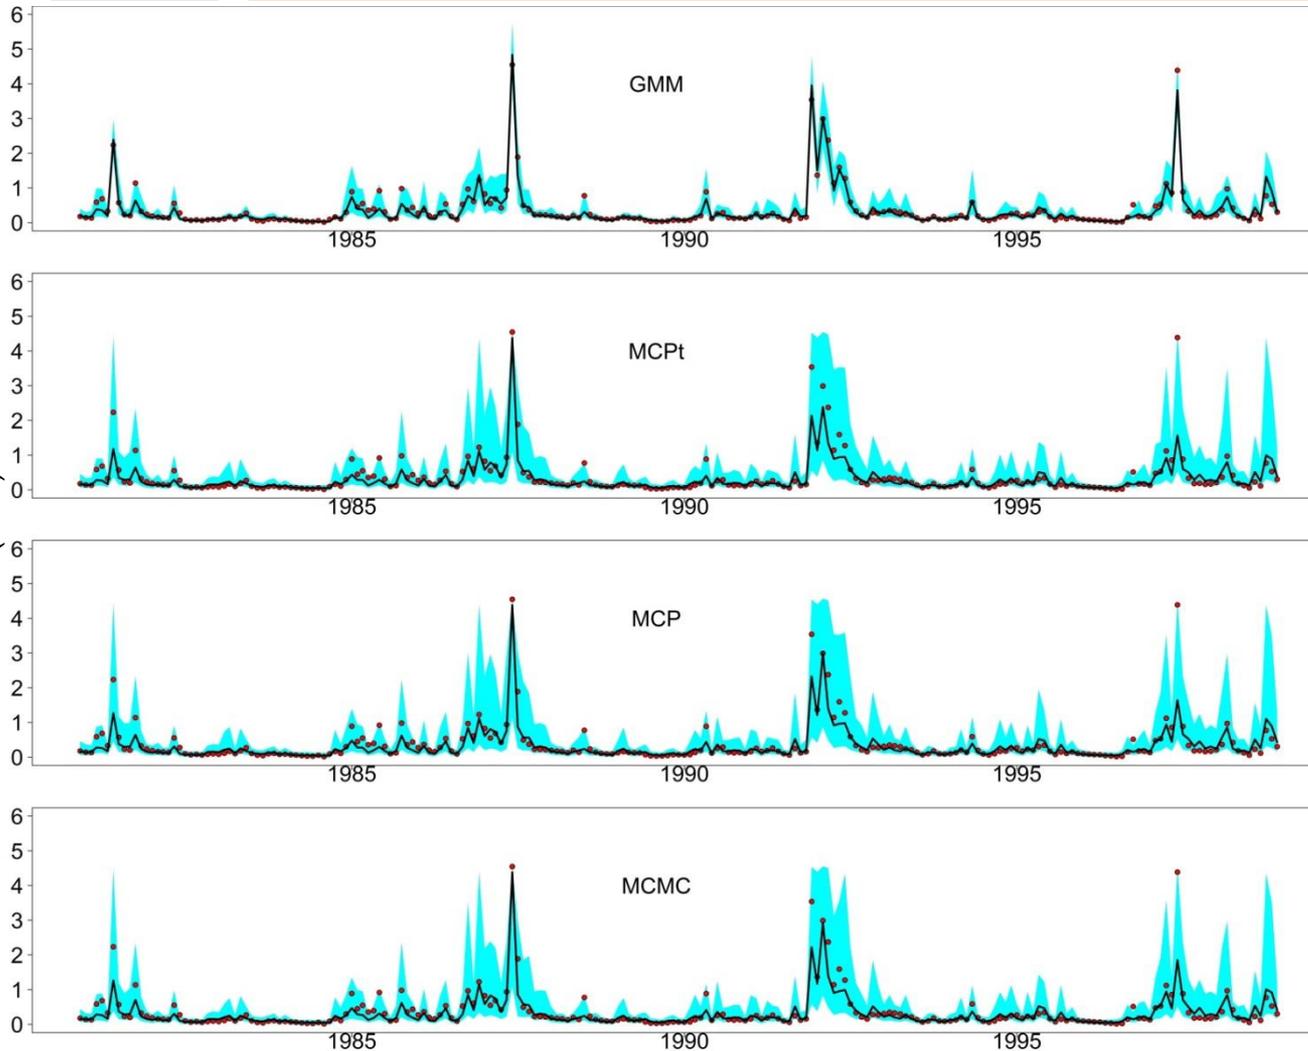


Cuencas ordenadas de la más humedad a la más seca



Bandas de incertidumbre de la cuenca Guadalupe

Las bandas de PP GMM son las más precisas, exactas y fiables

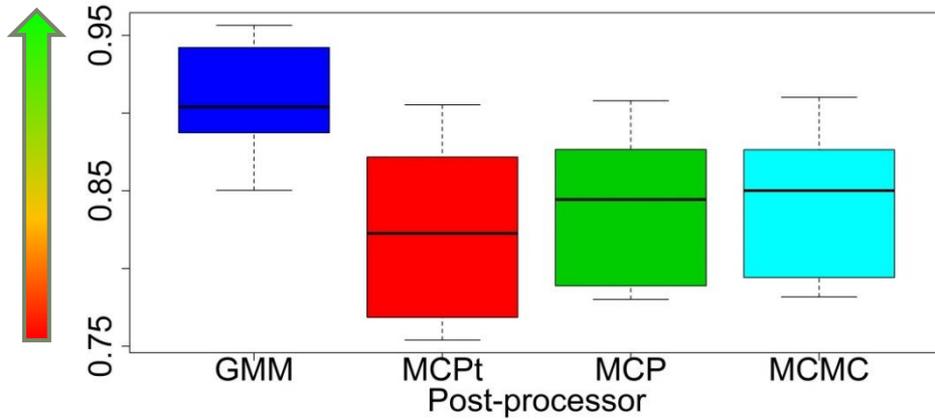


Incetidumbre predictiva (95%) durante el período de validación (1981-1998) para los cinco métodos evaluados



Resumen de los resultados en período de validación

Nash-Sutcliffe efficiency (NSE)





Conclusiones del post-procesador GMM

- ▶ El nuevo post-procesador GMM presenta el mejor desempeño en las métricas y las 12 cuencas evaluadas
- ▶ En términos de incertidumbre predictiva GMM produce las bandas más exactas, fiables y precisas
- ▶ Los otros post-procesadores MCP, MCPt y MCMC presentan un desempeño similar para caudales mensuales
- ▶ La evaluación del desempeño de los post-procesadores con diferentes condiciones hidroclicmáticas permite validar y generalizar los resultados
- ▶ Existe una cierta relación aunque no es muy clara (patrón) entre el índice de aridez y el desempeño de los post-procesadores. Sin embargo, no hay un patrón con el tamaño de la cuenca (No mostrado)

4. El problema de la verosimilitud intratable



Verosimilitud intratable

- ▶ El objetivo de la inferencia Bayesiana:

$$p(\theta|y^0) \propto p(\theta) \times p(y^0|\theta)$$

- ▶ La función de verosimilitud es intratable $p(y^0|\theta)$, si:
 - ▶ Esta completamente definida por un modelo probabilístico, $y \sim f(y^0|\theta)$
 - ▶ No esta disponible en forma analítica ni numérica (Marin et al. 2012)
- ▶ La verosimilitud intratable se presenta:
 - ▶ Se utilizan modelos complejos
 - ▶ La dimensión de los parámetros es muy alta
 - ▶ Ausencia de datos



Computación Bayesiana aproximada (ABC)

- ▶ Los métodos ABC surgen en el contexto de la genética para casos de verosimilitud intratable (Marin et al. 2012)
- ▶ Los métodos ABC se basan en el **intercambio** del cálculo de la verosimilitud por la comparación entre los **resúmenes estadísticos** de datos observados y simulados (Drovani y Pettitt, 2011)
- ▶ El objetivo es aproximar la distribución a posteriori, $p(\theta|y^0)$
- ▶ Mientras $p(y^0|\theta)$ es intratable se pueden **simular datos** de $p(y^0|\theta)$ y $p(\theta)$, por lo tanto se produce una estimación basada en simulación para **aproximar** $p(\theta|y^0)$ (Turner y Van Zandt, 2012)



ABC principio de funcionamiento

- ▶ Algoritmo Aceptación/Rechazo (Beaumont et al. 2002)
 - ▶ 1) Simular $\theta_i \sim p(\theta)$ desde la a priori
 - ▶ 2) Simular $y_i \sim L(y^o | \theta_i)$ desde el modelo generador de datos
 - ▶ 3) Aceptar θ_i si: $d\{\eta(y^o), \eta(y_i)\} \leq \varepsilon$
 - ▶ $\eta(\cdot)$ es un vector de resúmenes estadísticos
 - ▶ $d(\cdot)$ es un criterio de distancia
 - ▶ ε es el valor de tolerancia, la cual es arbitrariamente pequeña
- ▶ Se utilizaron cinco **resúmenes estadísticos**: el **promedio**, la **varianza**, la **asimetría**, la **curtosis** y la **autocorrelación**. Además, se utilizó la distancia **Euclidiana** y un nivel de **tolerancia de 0.01** (Fearnhead y Prangle, 2012)
- ▶ La distribución predictiva:

$$g(\widetilde{y}^o | \mathbf{y}^s) = \int_{\emptyset} p(\widetilde{y}^o | \boldsymbol{\theta}, \mathbf{y}^o, \mathbf{y}^s) p(\boldsymbol{\theta} | \mathbf{y}^o) d\boldsymbol{\theta}$$



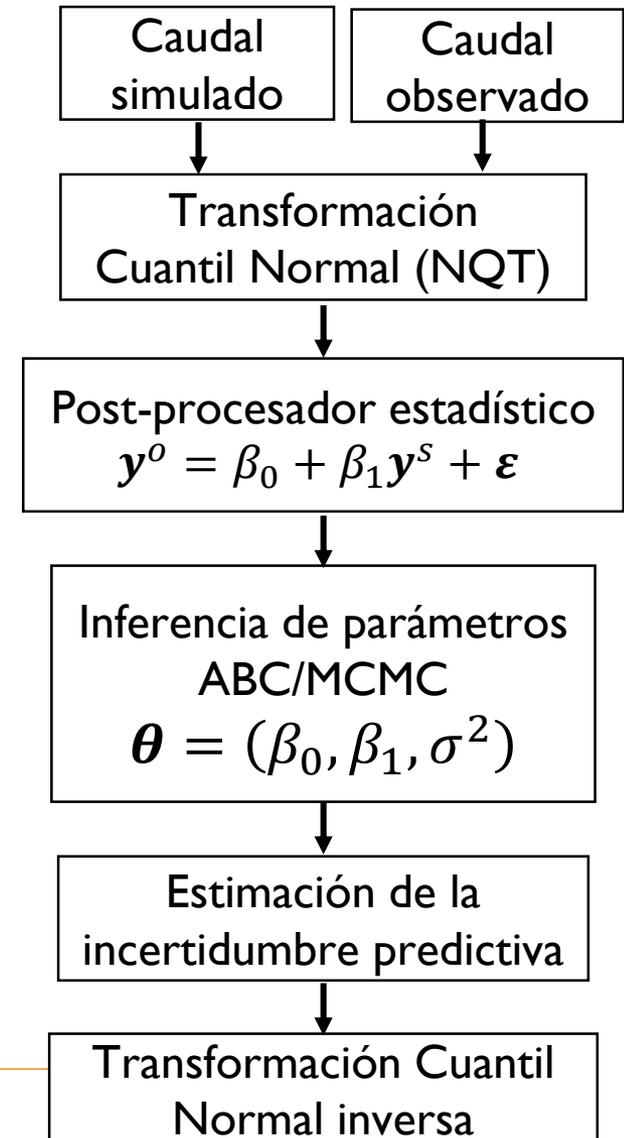
Objetivos específicos

- ▶ Proponer un post-procesador hidrológico basado en la computación Bayesiana aproximada (ABC) para la estimación de la incertidumbre predictiva de caudales mensuales cuando sea difícil calcular la función de verosimilitud
- ▶ Probar que la estimación de la incertidumbre predictiva con un método aproximado (ABC) puede ser similar a la de un método exacto (MCMC) en un experimento controlado



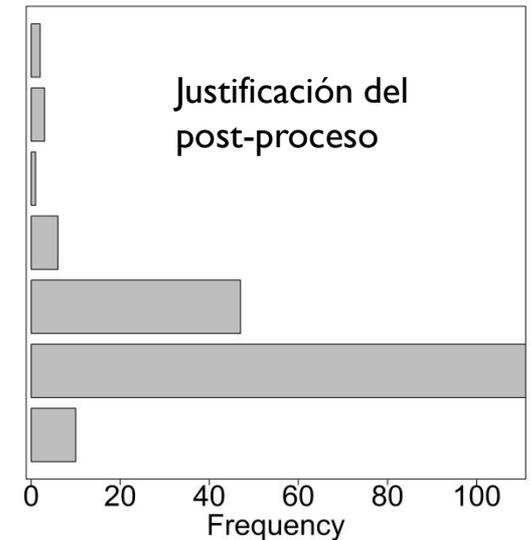
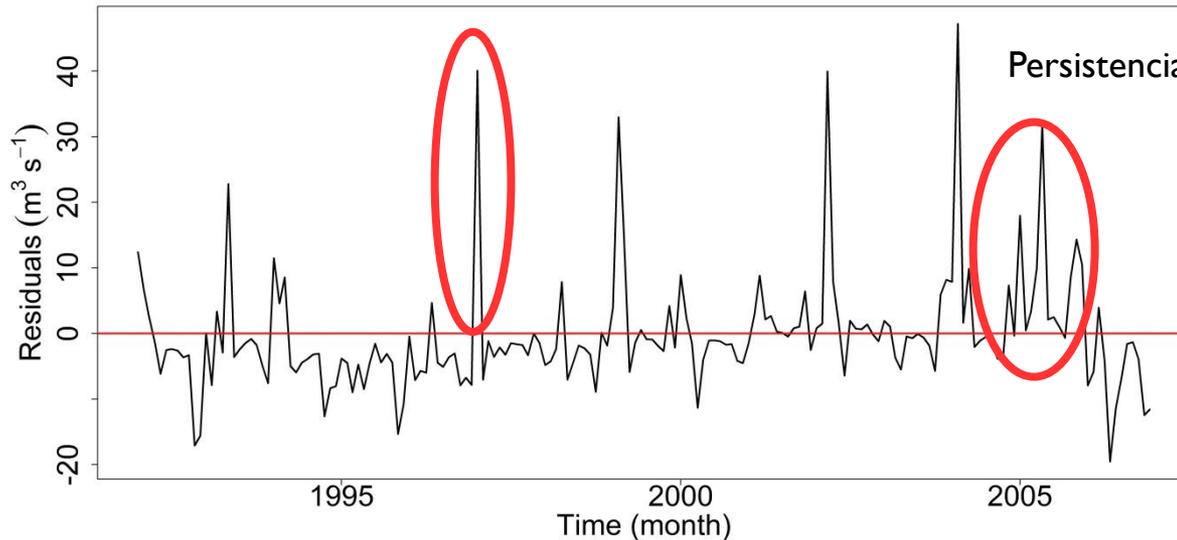
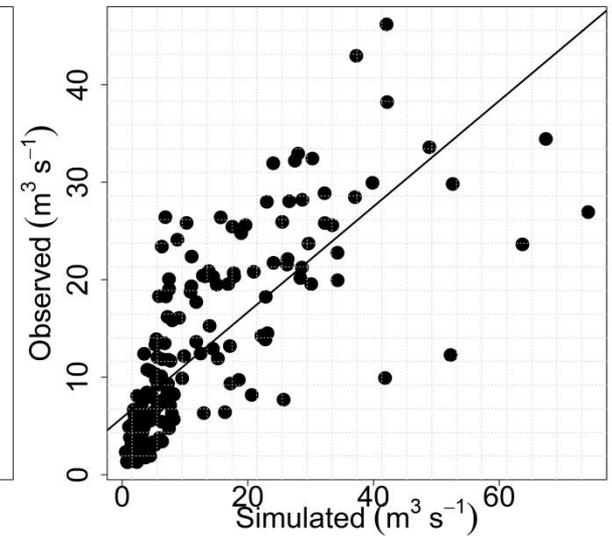
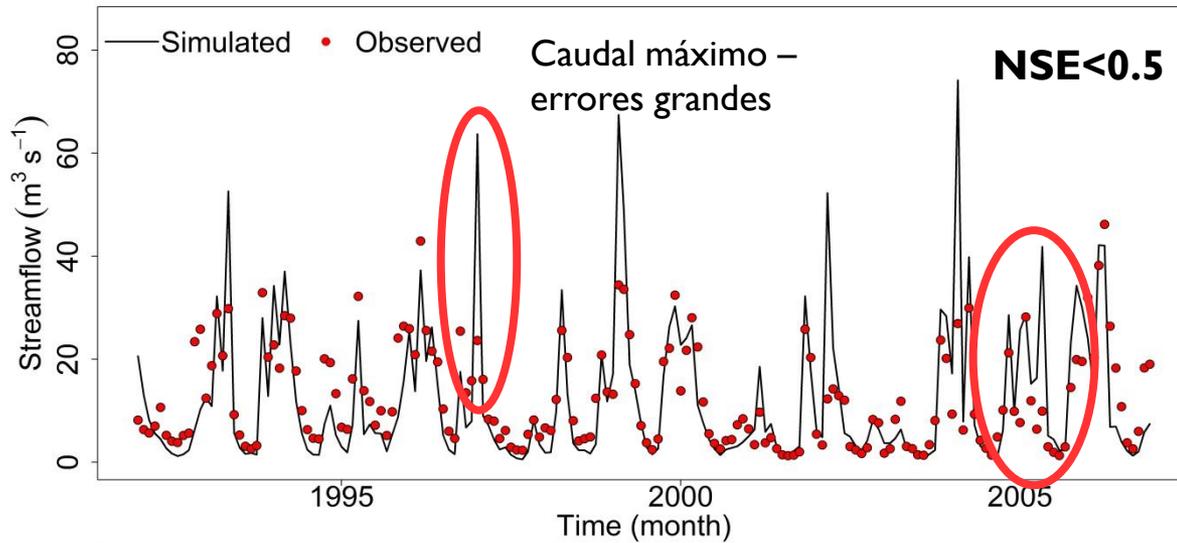
Esquema Metodológico

Escenario	Predicciones hidrológicas escenario I (NSE <0.5)	Predicciones hidrológicas escenario 2 (NSE >0.8)	
Modelo hidrológico	Abcd Thomas (agregado)	TETIS (distribuido)	
Clima	Tropical (Colombia)	Oceánico (España)	
Post-procesador	MCMC ABC	MCMC ABC	
Esquema modelación	Calibración/Validación (1992-2012)	Calibración/Validación (1987-2000)	
Métricas de desempeño	Exactitud	Precisión	Fiabilidad





Datos de entrada del post-procesamiento hidrológico en el escenario 1



Serie de tiempo de caudales observados y simulados en la cuenca del río Aipe



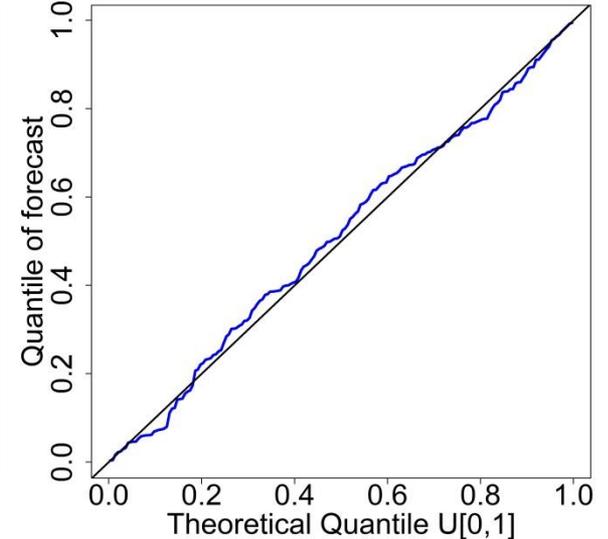
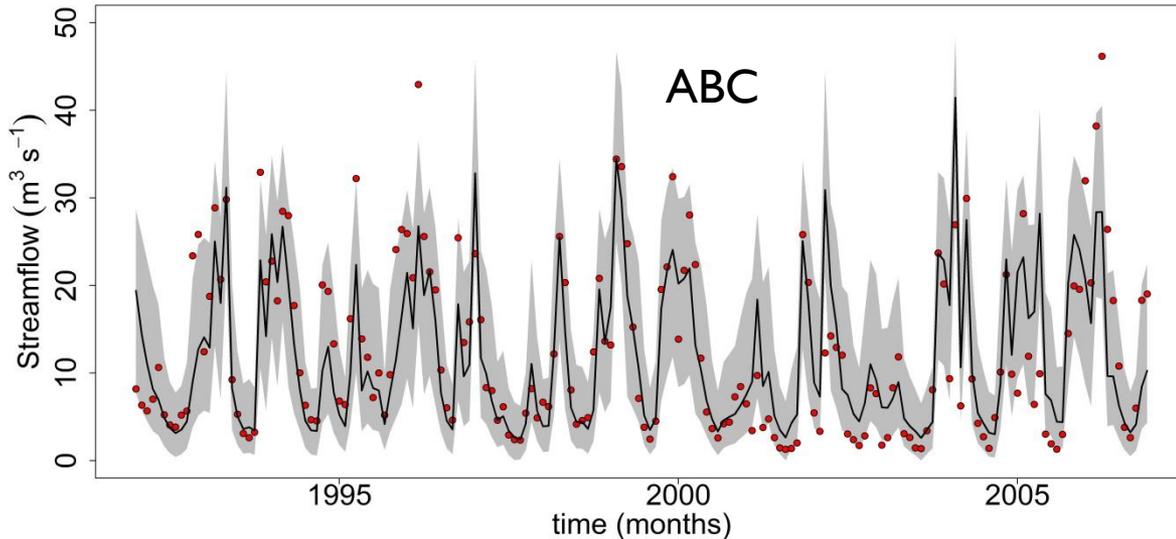
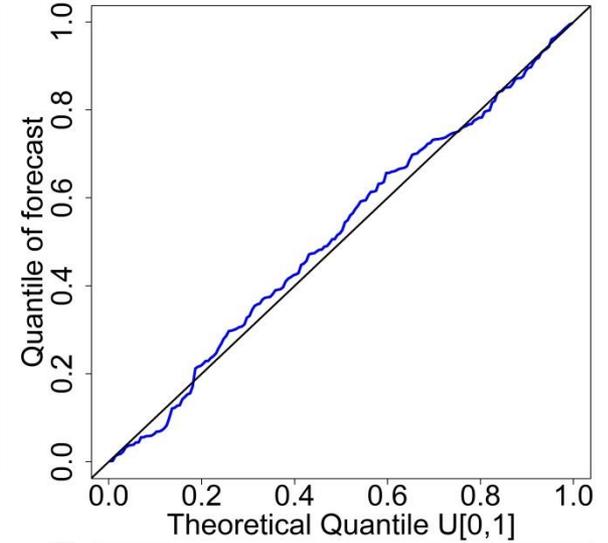
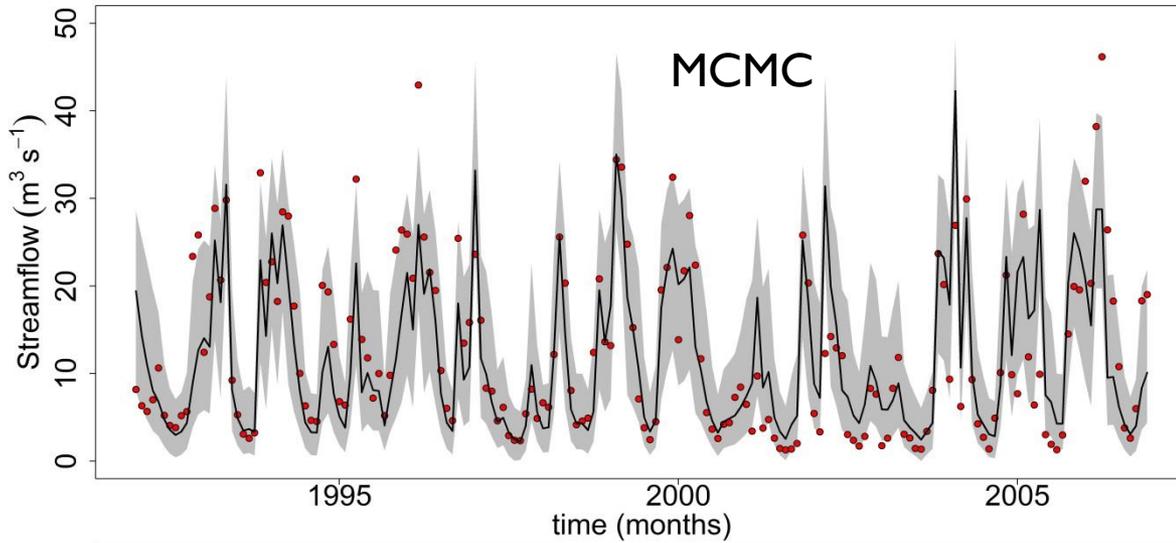
Métricas de desempeño para el escenario 1

Métrica de desempeño	Calibración			Validación		
	Predicciones deterministas	Post-proceso		Predicciones deterministas	Post-proceso	
		MCMC	ABC		MCMC	ABC
NSE	0.165	0.669	0.671	0.571	0.777	0.773
KGE	0.527	0.769	0.764	0.637	0.757	0.744
Fiabilidad		0.996	0.996		0.993	0.993
Precisión		2.403	2.306		2.581	2.5
K-S test (p-value)		0.465	0.75		0.132	0.223
B (m ³ s ⁻¹)		14.95	15.64		25.78	26.86
CR (%)		88.33	88.89		94.44	95.83
D (m ³ s ⁻¹)		6.82	6.92		12.23	12.42

- Las predicciones deterministas son muy pobres
- NSE incrementa un 74.63% en calibración y 25.84% en validación
- KGE incrementa un 30.3% en calibración y 16% en validación
- Los índices de los post-procesadores MCMC y ABC tiene valores muy similares



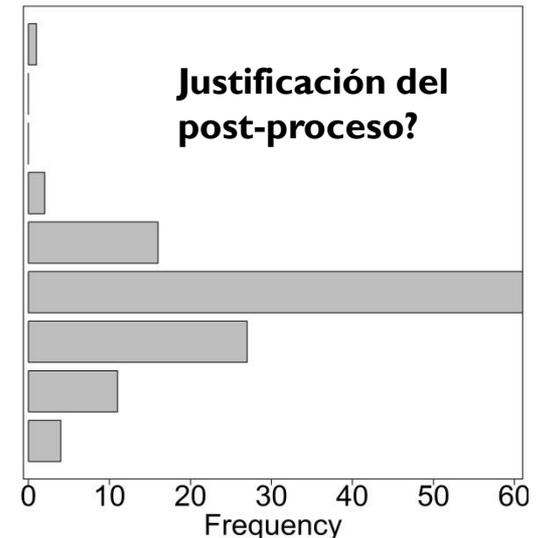
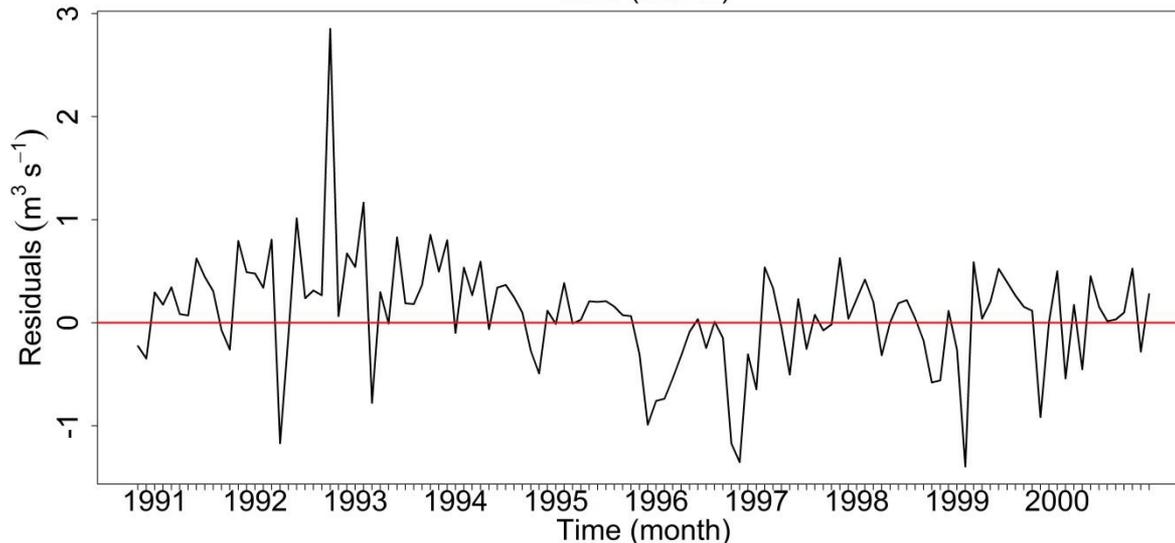
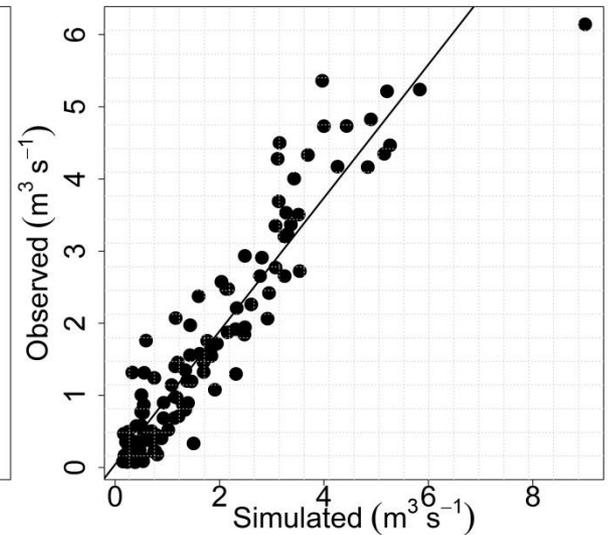
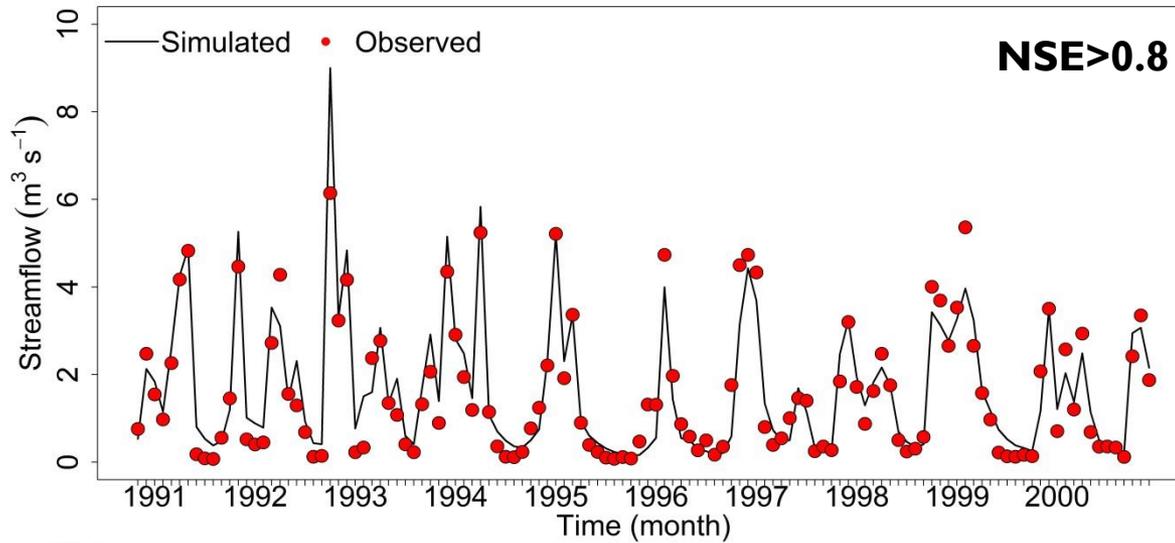
Comparación incertidumbre predictiva del MCMC y ABC en el escenario 1



Bandas de incertidumbre (95%) y Qqplot para la cuenca del río Aipe



Datos de entrada del post-procesamiento hidrológico en el escenario 2



Serie de tiempo de caudales observados y simulados en la cuenca del río Oria



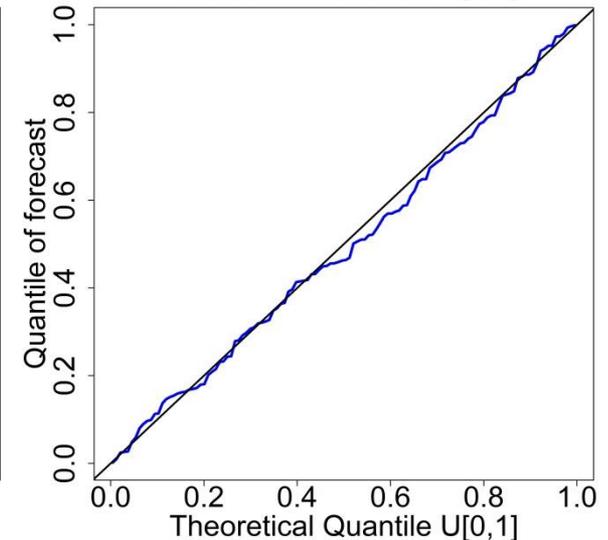
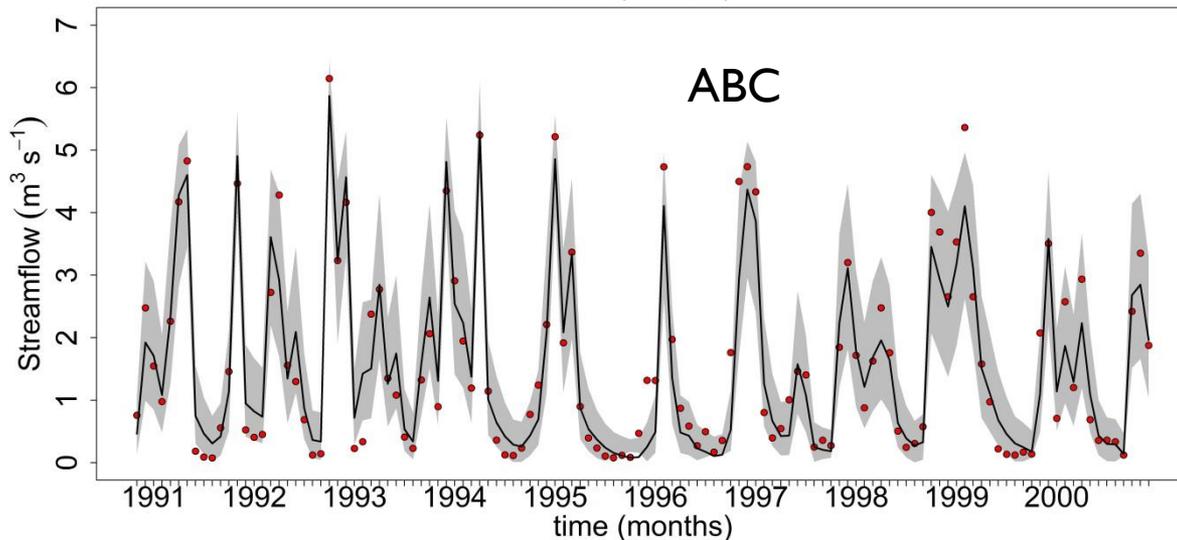
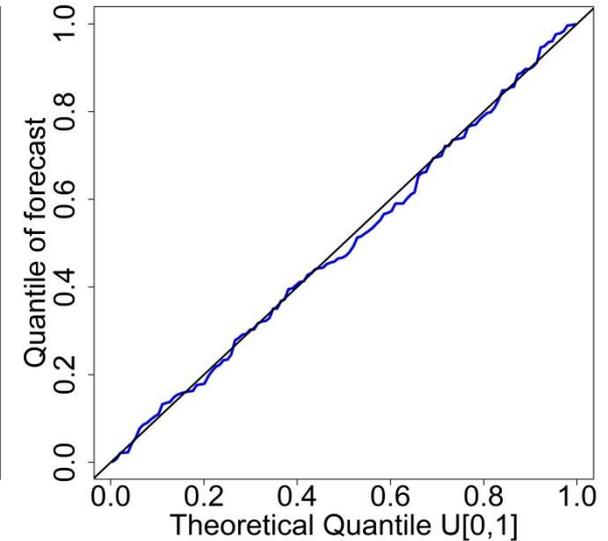
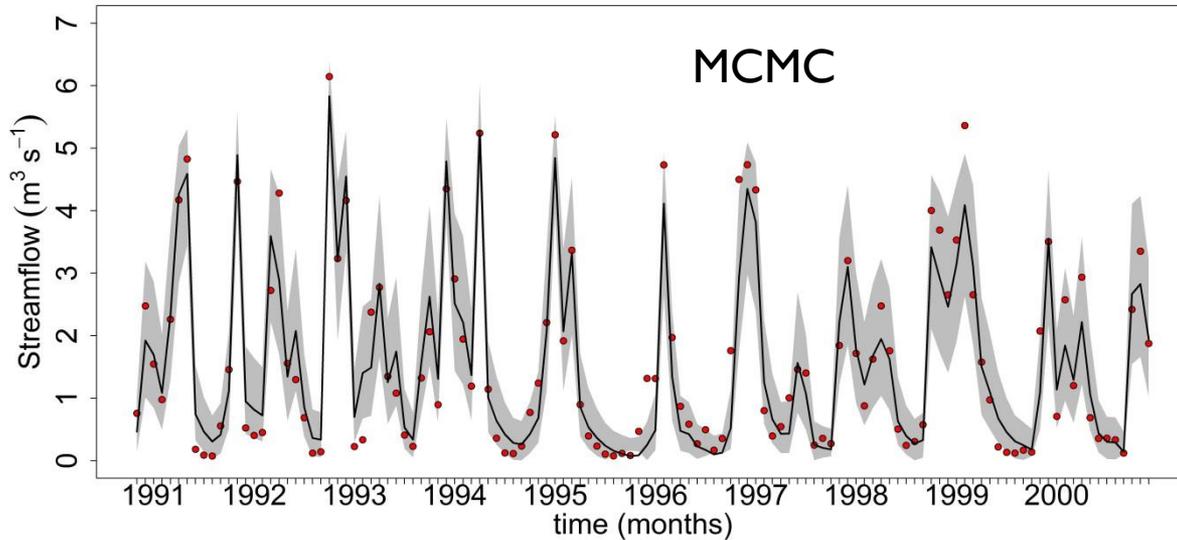
Métricas de desempeño para el escenario 2

Métrica de desempeño	Calibración			Validación		
	Predicciones deterministas	Post-proceso		Predicciones deterministas	Post-proceso	
		MCMC	ABC		MCMC	ABC
NSE	0.875	0.91	0.911	0.939	0.955	0.956
KGE	0.918	0.903	0.91	0.891	0.909	0.917
Fiabilidad		0.995	0.995		0.982	0.982
Precisión		2.95	2.87		2.28	2.19
K-S test (p-value)		0.972	0.923		0.868	0.872
B (m ³ s ⁻¹)		1.47	1.51		1.34	1.37
CR (%)		86.07	86.07		77.78	80.56
D (m ³ s ⁻¹)		0.85	0.86		0.66	0.67

- Las predicciones deterministas son buenas
- El post-procesamiento produce un mejoramiento en índices pero no es tan pronunciado como en el escenario 1
- NSE incrementa un 3.9% en calibración y 1.8% en validación
- Los índices de los post-procesadores MCMC y ABC tiene valores muy similares



Comparación incertidumbre predictiva del MCMC y ABC en el escenario 2



Bandas de incertidumbre (95%) y Qqplot para la cuenca del río Oria



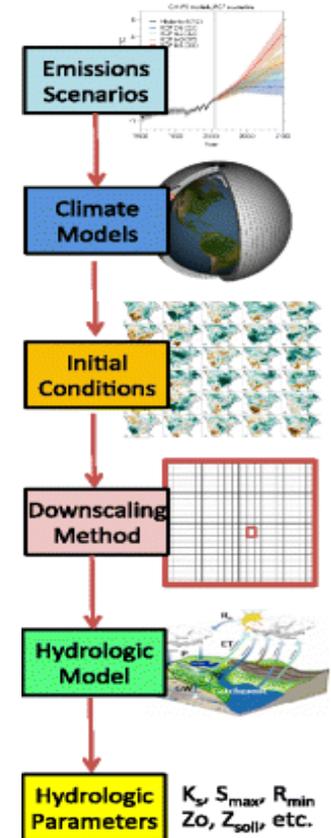
Conclusiones del post-procesador ABC

- ▶ El post-procesador ABC combina los conceptos de incertidumbre predictiva, post-procesamiento hidrológico y computación Bayesiana aproximada
- ▶ El post-procesador ABC (aproximado) presentan un desempeño similar al MCMC (exacto) en la estimación de la incertidumbre predictiva de caudales mensuales
- ▶ El post-procesamiento hidrológico mejora las predicciones hidrológicas de caudales mensuales especialmente cuando las predicciones son de mala calidad

5. Aplicación del Post-procesador ABC a las proyecciones de Cambio Climático

Introducción: Cambio Climático

- ▶ Evaluar los impactos negativos del cambio climático sobre los recursos hídricos es uno de los desafíos centrales del siglo XXI (Weaver et al. 2013)
- ▶ Los estudios de impacto del cambio climático sufren de muchas fuentes de incertidumbre (Clark et al. 2016)
 - ▶ Escenarios de emisión de carbono (Schenk y Lensink, 2007)
 - ▶ Modelos de Circulación Global (GCM) (Murphy et al. 2004)
 - ▶ Modelos Regionales de Clima (RCM) (Stoll et al. 2011)
 - ▶ Modelo hidrológico (Wilby y Harris, 2006)
 - ▶ Corrección de sesgo (Maraun et al. 2017)
 - ▶ Variabilidad natural del clima (von Trentini et al. 2019)



Tomado de
Clark et al. (2016)



Incertidumbre en Cambio Climático

Ensemble multi-modelo

- Todos los miembros del *ensemble* tienen igual peso
- Preferido por la comunidad climática a escala global (Christensen et al. 2010)
- Recomendado por IPCC para representar la incertidumbre (Adler y Hirsch, 2014)

Ensemble multi-modelo ponderado

- Pondera los miembros del *ensemble* de acuerdo con su desempeño en el período histórico
- La ponderación no es una tarea trivial (Mauran et al. 2010)
- Preferido por la comunidad hidrológica (Krysanova et al. 2018)

En general, los estudios de impacto del Cambio Climático basados en ensemble multi-modelos producen resultados más robustos (Krysanova y Hattermann, 2017)



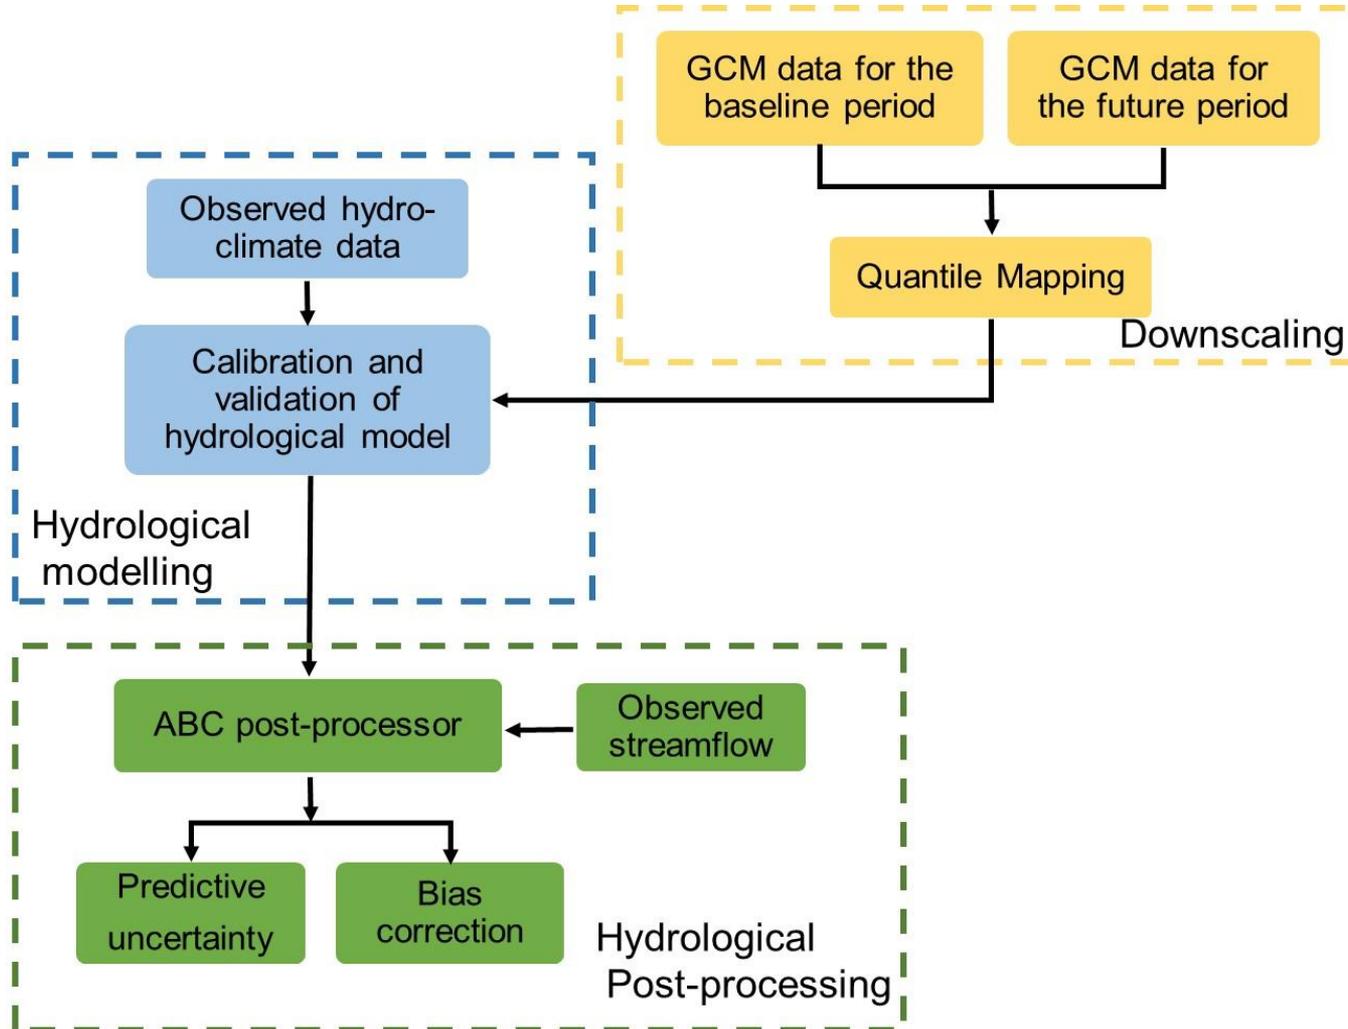
Proyecciones de Cambio Climático (CC)

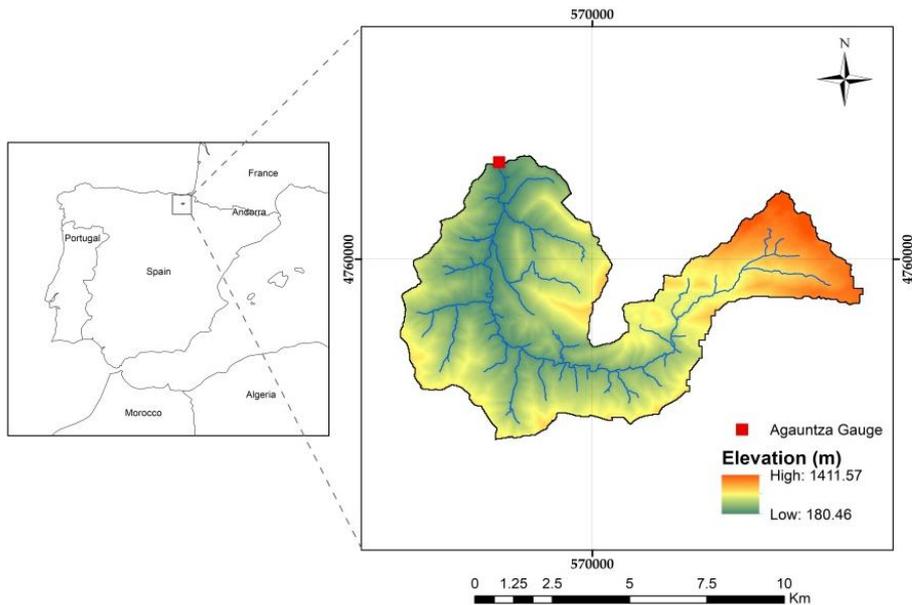
- ▶ Los modelos de CC no representan la evolución temporal del clima, pero si los **estadísticos** del clima (Maraun et al. 2010). En otras palabras, las proyecciones del CC no están en **sincronía** con las observaciones (Maraun et al. 2016)
- ▶ La evaluación de la incertidumbre de las proyecciones de CC se debe realizar sobre sus **estadísticos** y no sobre su serie de tiempo (Zhao et al. 2017)
- ▶ Existe poca información sobre análisis de incertidumbre **basado en estadísticos**. Sin embargo, esta condición se puede abordar como un caso de **verosimilitud intratable**



Objetivos específicos

- ▶ Estimar la incertidumbre predictiva de los estadísticos de los caudales mensuales de las proyecciones de cambio climático (AR5 - IPCC) utilizando el post-procesador ABC





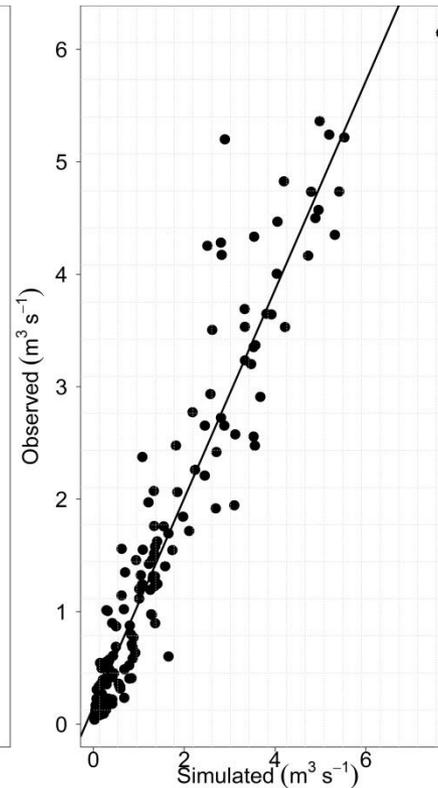
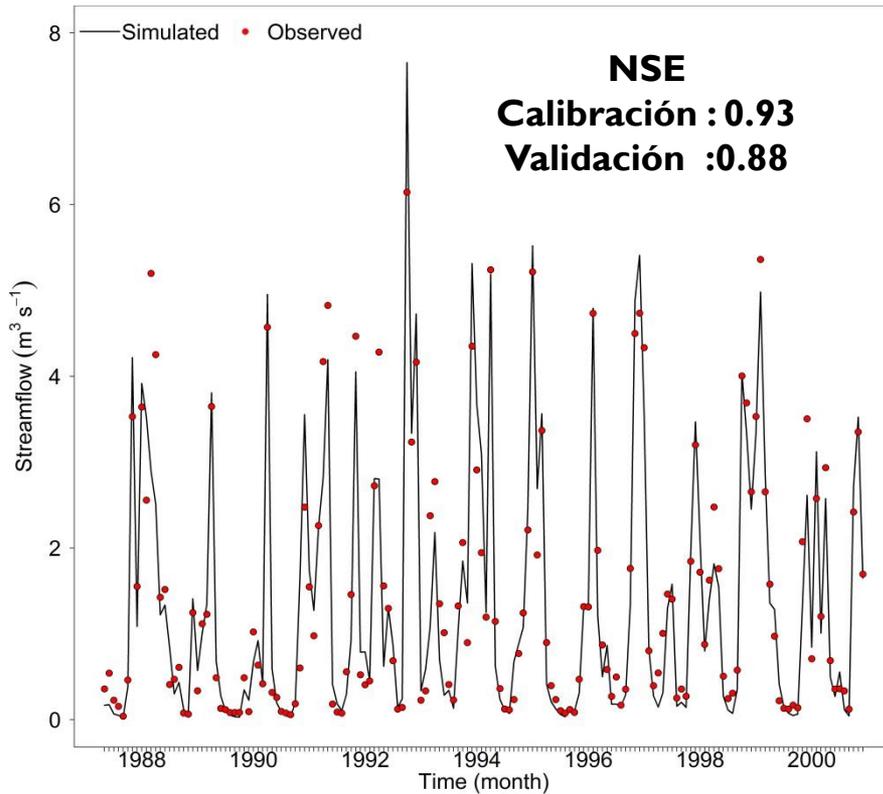
- ▶ Cuenca alta del río Oria
- ▶ Área: 73 km^2 ; $\Delta x: 100 \text{ m}$
 - ▶ Clima oceánico:
 - ▶ Caudal medio: 765 mm
 - ▶ Precipitación: 1498 mm
 - ▶ Evapotranspiración: 733.4 mm
 - ▶ Índice de aridez : 0.489
 - ▶ Índice de escorrentía : 0.511
 - ▶ Modelo hidrológico: TETIS
 - ▶ Series de tiempo diarias: 1987-2000
 - ▶ Calibración: Optimización de NSE con SCE-UA



Datos de Cambio Climático

- ▶ Proyecciones de CC descargadas de la Agencia Española de Meteorología AEMET (<http://www.aemet.es>)
 - ▶ Quinto informe de evaluación del IPCC (AR5)
 - ▶ 14 proyecciones de cambio climático (GCM-RCM)
 - ▶ Downscaling: Análogo (Lorenz, 1969)
 - ▶ Corrección de sesgo: Quantile mapping (Gudmundsson et al. 2012)
 - ▶ Series diarias de precipitación, temperatura máxima y mínima
- ▶ Las series de CC corregidas → TETIS (calibrado y validado) → Simulación caudales (1987-2000)
- ▶ Agregación mensual → post-procesador ABC → incertidumbre predictiva (1987-2000)

Predicciones hidrológicas durante el período de control

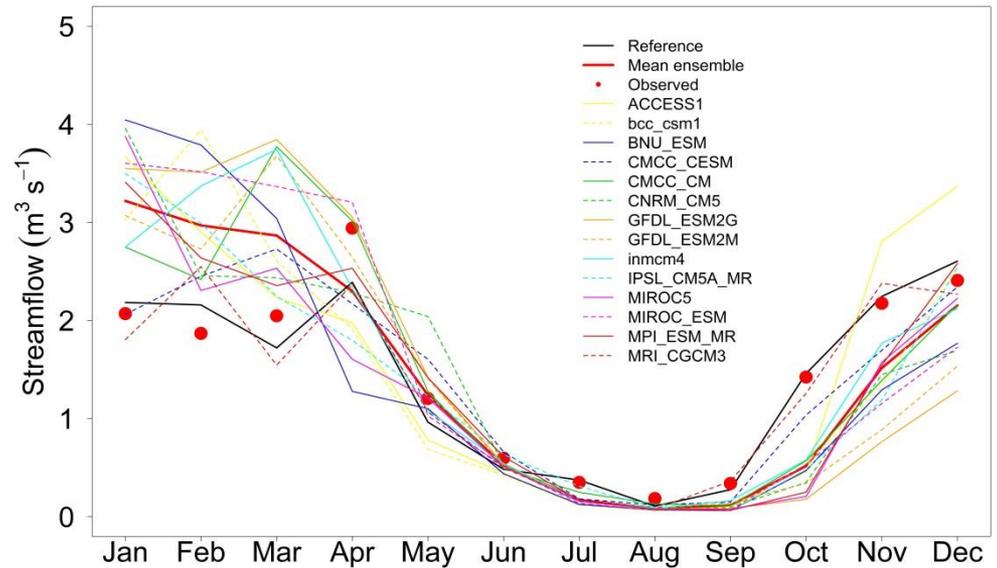


- ✓ Los caudales simulados se ajustan a las observaciones
- ✓ Los índices de desempeño son buenos
- ✓ Los parámetros del modelo son adecuados para utilizarlos en simulación

Serie de tiempo de caudales observados y simulados en la cuenca del río Oria



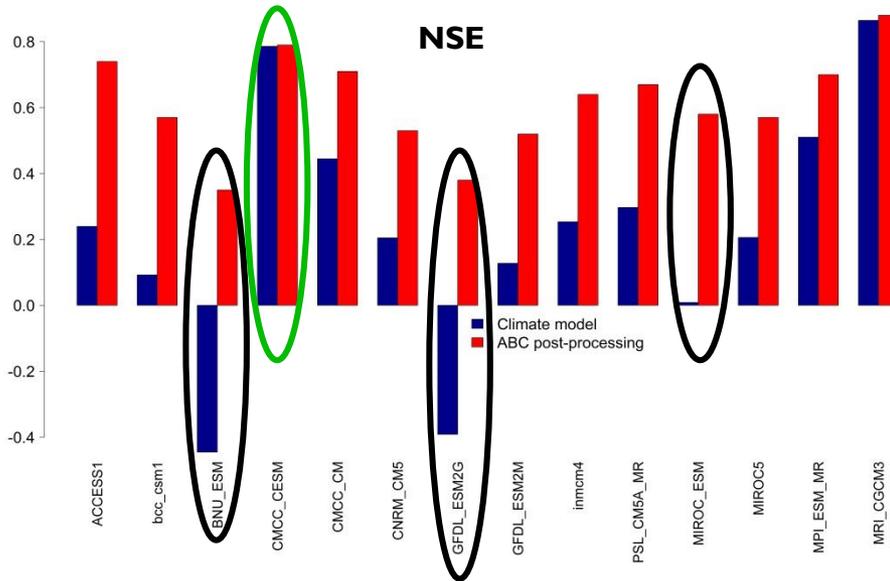
Comportamiento de los caudales estacionales de las proyecciones de Cambio Climático



✓ Los caudales altos son sobre estimados y los caudales bajos son sub estimados

- ✓ Caudales medios mensuales durante el período de control (1987-2000)
- ✓ Se presenta un sesgo estacional
- ✓ Necesidad de corregir aun más las proyecciones

Métricas del post-procesamiento

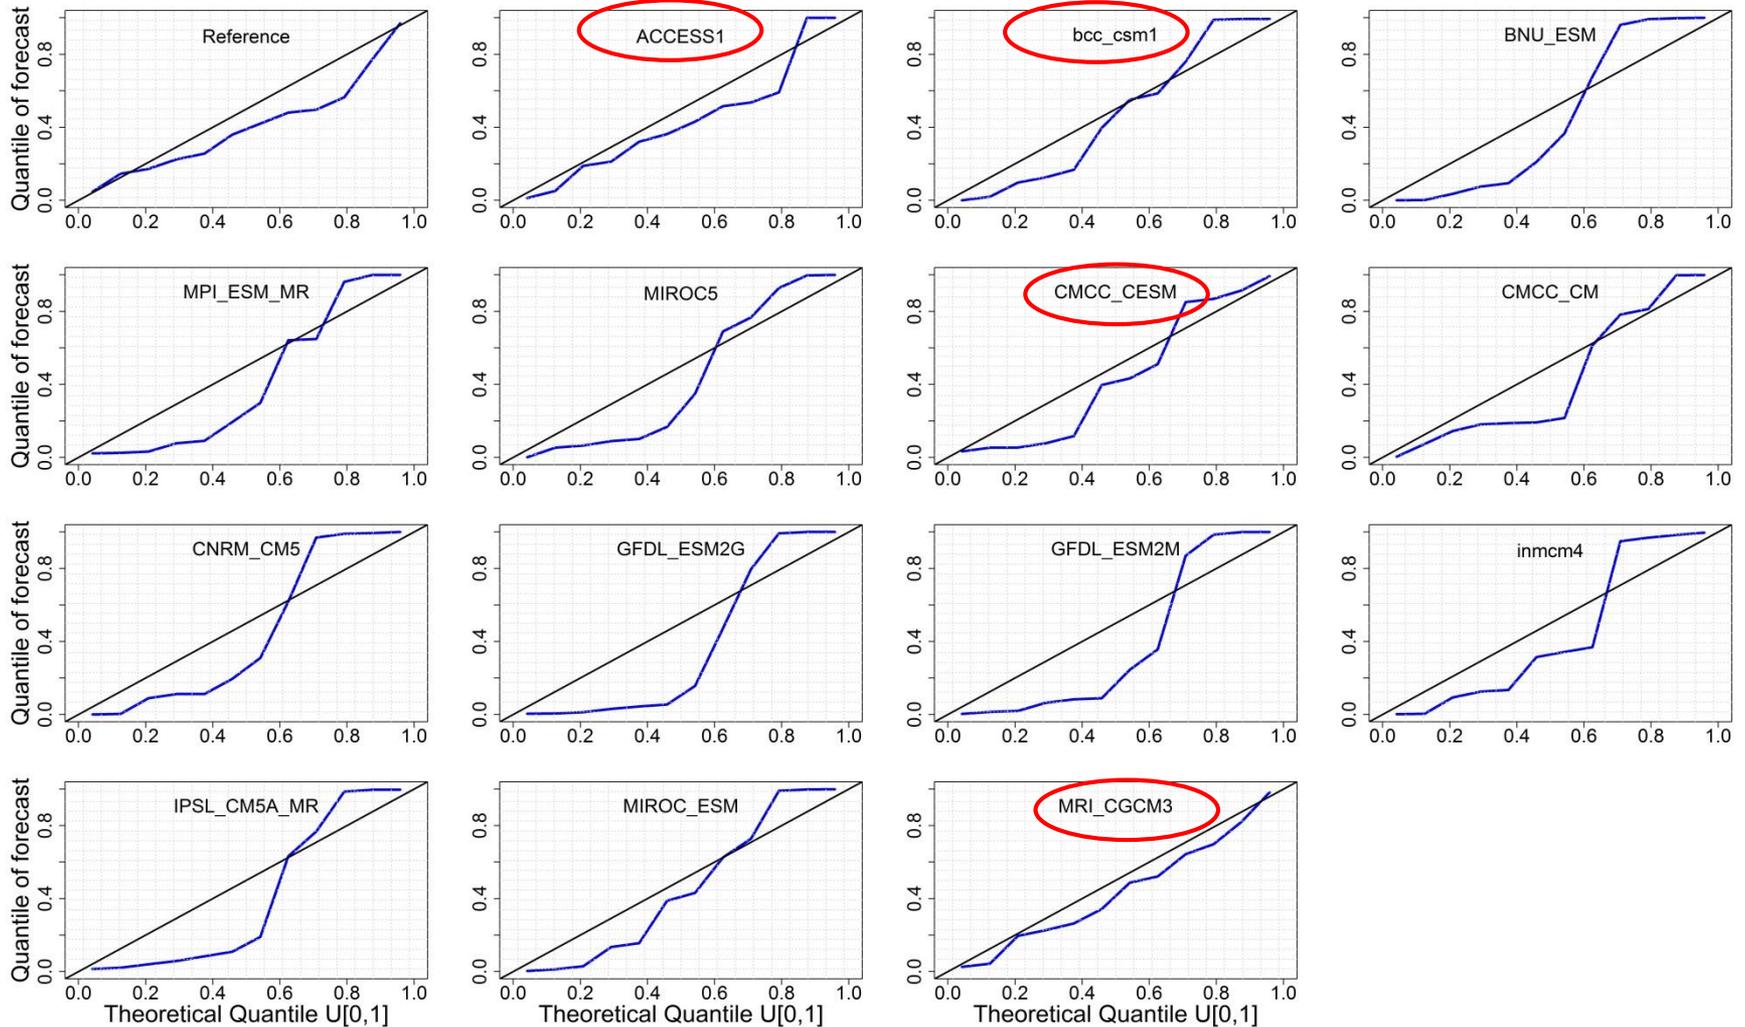


Modelo	NSE	KGE	CR (95%)	Precisión	K-S test	Fiabilidad
Reference	0.93	0.87	100.00	5.49	0.30	0.94
ACCESS1	0.74	0.87	75.00	5.37	0.42	0.95
bcc_csm1	0.57	0.78	58.30	5.40	0.43	0.96
BNU_ESM	0.35	0.69	58.30	5.30	0.24	0.96
CMCC_CESM	0.79	0.87	91.70	5.56	0.21	0.96
CMCC_CM	0.71	0.85	75.00	5.43	0.09	0.96
CNRM_CM5	0.53	0.79	58.30	5.37	0.17	0.96
GFDL_ESM2G	0.38	0.70	50.00	5.39	0.02	0.96
GFDL_ESM2M	0.52	0.76	50.00	5.41	0.04	0.96
inmcm4	0.64	0.82	66.70	5.52	0.18	0.96
IPSL_CM5A_MR	0.67	0.83	58.30	5.45	0.03	0.96
MIROC_ESM	0.58	0.77	58.30	5.30	0.33	0.97
MIROC5	0.57	0.79	75.00	5.32	0.10	0.10
MPI_ESM_MR	0.70	0.85	66.70	5.37	0.17	0.96
MRI_CGCM3	0.88	0.89	83.30	5.44	0.89	0.94

- ▶ El post-procesamiento mejora el NSE y el KGE:
 - ▶ MIROC_ESM → NSE ↑ +77.2%
 - ▶ CMCC_CESM → NSE ↑ +0.4%
- ▶ Los modelos climáticos presentan alta variabilidad:
 - ▶ NSE: 0.35 - 0.88 (53%)
 - ▶ KGE: 0.69- 0.89 (20%)
 - ▶ CR(95%): 50-91.7 (41.7%)

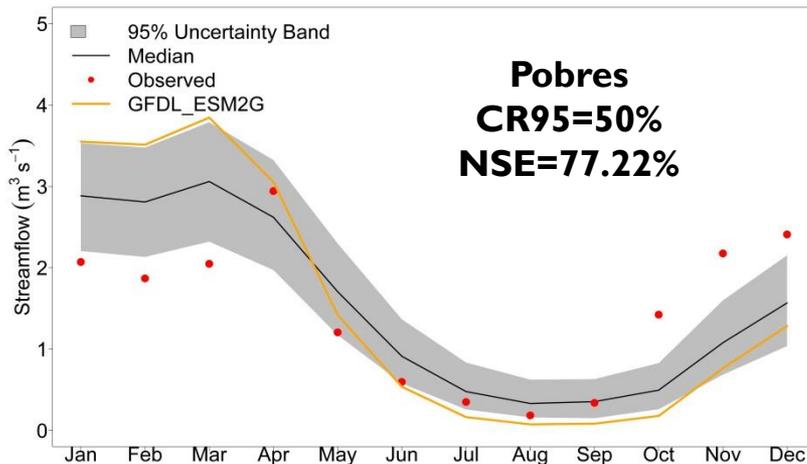
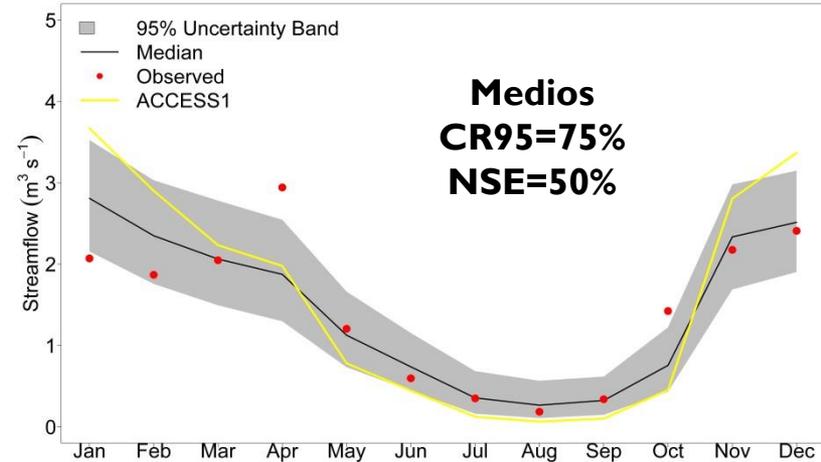
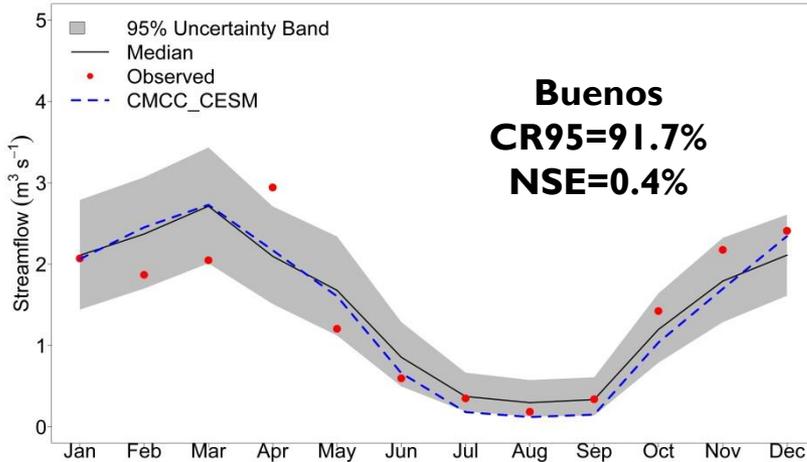


Qqplot de los modelos de cambio climático





Incertidumbre predictiva de tres modelos de CC



- ▶ Cuando las proyecciones de CC son malas el post-procesamiento mejora la corrección del sesgo, pero sacrifica la estimación de la incertidumbre



Conclusiones del post-procesador ABC en CC

- ▶ El post-procesamiento hidrológico presenta una estimación de la incertidumbre de los estadísticos de caudales mensuales **más fiable y menos sesgada** que los 14 modelos de CC
- ▶ Si la calidad de las proyecciones de CC durante el período de control es mala, el post-procesamiento mejora la corrección del sesgo, pero sacrifica la estimación de la incertidumbre
- ▶ Las proyecciones de CC sin post-procesamiento resultaron ser más sesgadas
- ▶ El post-procesamiento hidrológico puede llegar a **complementar el método** del “ensemble multi-modelo” en la estimación de la incertidumbre del cambio climático

6. Conclusiones



Conclusiones

- ▶ Esta tesis contribuye al desarrollo de **predicciones hidrológicas** más **exactas** y a la **fiable** y **precisa** cuantificación de la **incertidumbre predictiva** de los **caudales mensuales** a través de la aplicación de métodos de **post-procesamiento hidrológico**
- ▶ La principal aportación de la Tesis es la mejora de los métodos de post-procesamiento hidrológico para cuantificar la incertidumbre predictiva de los caudales mensuales, abordando dos retos científicos, la heterocedasticidad y la verosimilitud intratable:



Conclusiones

- ▶ Para abordar la **heterocedasticidad** se propone el **post-procesador GMM**, el cual, produce las bandas de incertidumbre más exactas, fiables y precisas
- ▶ Para abordar la **verosimilitud intratable** se propone el **post-procesador ABC** (método aproximado), el cual, produce resultados similares a los obtenidos con un método exacto como el post-procesador MCMC
- ▶ Se implementó el **post-procesador ABC** para estimar la incertidumbre predictiva de los estadísticos de los caudales mensuales proyectados de **cambio climático** como ejemplo de **verosimilitud intratable**



Conclusiones generales

- ▶ Todos los post-procesadores utilizados en esta investigación fueron programados en **software libre** (R) con el propósito de facilitar la replica de los resultados
- ▶ Probar las hipótesis hidrológicas con diferentes condiciones ambientales es muy importante para **generalizar resultados** y crear conocimiento hidrológico
- ▶ Esta tesis propone un método simple para estimar la incertidumbre predictiva de las predicciones hidrológicas puntuales (deterministas)
- ▶ El análisis de incertidumbre permite apoyar la toma de decisiones de manera informada



Líneas futuras de investigación en post-procesamiento hidrológico

- ▶ Extender de los post-procesadores propuestos a nivel multivariado, es decir, utilizando múltiple modelos (predictores)
- ▶ Evaluar el potencial del post-procesador ABC en cuencas no aforadas
- ▶ Evaluar los post-procesadores propuestos con otras variables hidroclicmáticas (precipitación, contenido de humedad del suelo, temperatura, niveles, etc.) y a diferentes escalas de tiempo como horaria, diaria, semanal, etc.



Líneas futuras de investigación en post-procesamiento hidrológico

- ▶ Eliminar la transformación de variables en el post-procesamiento
- ▶ Post-procesar series de valores extremos
- ▶ Post-procesar series con datos faltantes
- ▶ Proponer post-procesadores que funcionen bajo condiciones no estacionarias



Artículos publicados

- ▶ Artículo en revistas científica no JCR:
 - ▶ **Romero-Cuellar, J.**, Buitrago-Vargas, A., Quintero-Ruiz, T., Francés, F (2018) Modelling the potential impacts of climate change on the hydrology of the Aipe river basin in Huila, Colombia, Ribagua, 5:1, 63-78, DOI: 10.1080/23863781.2018.1454574.
- ▶ Artículo en revista científica JCR:
 - ▶ **Romero-Cuellar, J.**, Abbruzzo, A., Adelfio, G., Francés, F (2019) Hydrological post-processing based on approximate Bayesian computation (ABC), Stoch Environ Res Risk Assess, 33, 1361-1373, DOI: 10.1007/s00477-019-01694-y.



Artículos en proceso de publicación

- ▶ **Romero-Cuellar, J.,** Gastulo-Tapia CJ., Hernández-López, MR., Francés, F. Assessing post-processing approaches for monthly streamflow in 12 MOPEX catchments. *Journal of Hydrology*, (En revisión).
- ▶ **Romero-Cuellar, J.,** Francés, F. Estimating the uncertainty of monthly streamflow from climate projections using a post-processing approach. (Borrador finalizado).



Participación en congresos

- ✓ Hernández-López, M.R., **Romero-Cuellar, J.**, Múnera-Estrada, J.C., Coccia, G., Francés, F. (2017). Performance of two predictive uncertainty estimation approaches for conceptual Rainfall-Runoff Model: Bayesian Joint Inference and Hydrologic Uncertainty Post-processing. Geophysical Research Abstracts. Vol. 19, **EGU2017-14782**.
- ✓ **Romero-Cuellar, J.**, Adelfio, G., Francés, F. (2018). Estimating predictive hydrological uncertainty by dressing a probabilistic post-processing approach; a comparison with application to a tropical catchment. Geophysical Research Abstracts. Vol. 20, **EGU2018-6915**.
- ✓ **Romero-Cuellar, J.**, Abbruzzo, A., Adelfio, G., Francés, F. (2018). Approximate Bayesian computation for forecasting in hydrological models, In proceedings of the **49th Meeting of the Italian Statistical Society (SIS 2018)**. Palermo, Italy
- ✓ **Romero-Cuellar, J.**, Abbruzzo, A., Adelfio, G., Francés, F. (2018). Monthly hydrologic post-processor using approximate Bayesian computation, In **2nd VIBASS WORKSHOP**. Valencia, Spain.
- ✓ **Romero-Cuellar, J.**, Francés, F., Gastulo-Tapia CJ., Hernández-López. (2019). A comparison of the performance of different post-processors of monthly flows in some basins of the MOPEX project, In the tenth edition of the **STAHY International Workshop**. Nanjing, China



Otro méritos académicos

- ▶ Estancia de investigación en el **departamento de estadística** de la Universidad de Palermo, Italia (6 meses)



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



UNIVERSITÀ
DEGLI STUDI
DI PALERMO

máster en ingeniería
hidráulica y medio ambiente
mihma

- ▶ Codirección de 2 tesis de máster:
 - ▶ Comparación de post-procesadores estadísticos para la obtención de la incertidumbre predictiva de las simulaciones hidrológicas a escala mensual. Cristhian Gastulo. 2019
 - ▶ Aplicación práctica de un post-procesador para la estimación de la incertidumbre en la predicción estacional de precipitación y de aportaciones de caudal mensuales. Fergie Arenas. 2019



Gracias por su atención!

► AGRADECIMIENTOS

Gobernación del Huila (Colombia) programa de becas de doctorado en el extranjero 677

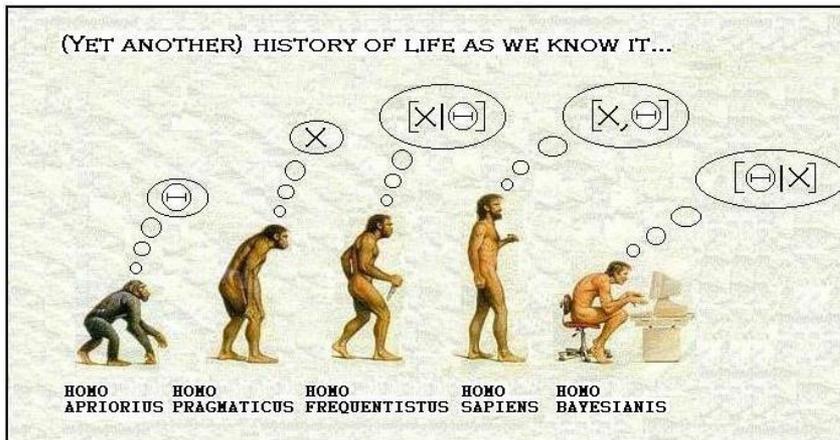
Ministerio de Ciencia e Innovación de España

Qignyun Duan por los datos del proyecto MOPEX

► PROYECTOS

TETISCHANGE (RTI2018-093717-B-I00),

TETISMED (CGL2014-58127-C3-3-R)



GOBERNACION DEL HUILA



COLCIENCIAS



COLFUTURO



Instituto de Ingeniería del
Agua y Medio Ambiente