



UNIVERSIDAD DE LA REPÚBLICA
FACULTAD DE INGENIERÍA

Tesis para optar al Título de
Magister en Ingeniería

**DESARROLLO DE UN GENERADOR
ESTOCÁSTICO DE PRECIPITACIÓN DIARIA
Y SU APLICACIÓN EN URUGUAY**

MAESTRÍA EN INGENIERÍA - MECÁNICA DE LOS FLUIDOS APLICADA

Autor: Ing. Alejandra De Vera

Tutor: Dr. Ing. Rafael Terra

Montevideo, Uruguay

Diciembre de 2014

Agradecimientos

A Rafael Terra, tutor de este trabajo, por su enorme dedicación, confianza y apoyo brindados desde el primer día que ingresé al IMFIA y comencé a trabajar junto a él. Gracias por su continua motivación.

A la Agencia Nacional de Investigación e Innovación (ANII), por haberme otorgado una beca de posgrado para la realización de la maestría.

A mis compañeros del IMFIA, quienes hacen más disfrutables las jornadas de trabajo, por su apoyo en diversos aspectos técnicos y humanos. En especial a Álvaro Díaz por su disposición y ayuda en las etapas iniciales de esta tesis, y a Mane por su gran optimismo, generosidad y compañía en el día a día.

A los investigadores del IRI, Universidad de Columbia, por el tiempo dedicado y la orientación brindada durante la estadía en dicha institución, de la cual surgieron aportes muy interesantes para este trabajo de tesis.

A mi familia y amigos, por su inmenso cariño, interés y aliento continuo durante todo este tiempo. Por estar siempre pendientes y ayudarme en lo que esté a su alcance.

A Pablo, mi gran compañero, por su infinita comprensión, confianza en mí y apoyo incondicional, imprescindibles para lograr este trabajo.

Muchas gracias a todos!

Resumen

En el presente trabajo se formularon generadores de tiempo para la simulación de la precipitación diaria y se evaluó su desempeño en base a registros pluviométricos en 22 estaciones de Uruguay.

Se implementaron dos modelos, ambos basados en una cadena de Markov de primer orden para simular la ocurrencia de precipitación diaria; el primero (de cuatro parámetros) usa una distribución gamma para simular la cantidad de precipitación de los días lluviosos y el segundo (de cinco parámetros) una distribución exponencial mixta. Se evaluó la adopción de parámetros estacionarios y variables a lo largo del año, siendo indiscutible la ventaja de la segunda alternativa. Si bien la distribución exponencial mixta tiene un desempeño marginalmente superior que la gamma, la mejora no justifica el uso de un modelo menos parsimonioso.

Se procedió luego a la incorporación de sesgos climáticos (asociados al fenómeno ENOS) al generador de tiempo. Como variable de condicionamiento se tomó el índice N3.4 en el trimestre Noviembre-Enero, de modo de producir secuencias sintéticas consistentes con un escenario determinado. Los resultados obtenidos muestran que el procedimiento desarrollado logra capturar satisfactoriamente la señal de ENOS, lo cual abre oportunidades muy interesantes para la aplicación de pronósticos estacionales asociados a ENOS en diversos sectores.

Algunas aplicaciones requieren considerar la precipitación acumulada sobre un área de cierta extensión, lo cual exige considerar también la correlación espacial entre distintos puntos. Para ello se modificó el modelo puntual de forma tal de generar un conjunto de modelos individuales con sorteos aleatorios temporalmente independientes pero espacialmente correlacionados, a través de la simulación simultánea de secuencias de tiempo en múltiples puntos. Las series simuladas de esta manera reproducen de manera satisfactoria los estadísticos seleccionados de las series observadas, siendo notoria la ventaja de incorporar la correlación espacial entre estaciones.

En definitiva, se obtuvo una herramienta de modelación estocástica de precipitación diaria en Uruguay de utilidad en diversas aplicaciones y capaz de reproducir el clima medio de la variable de interés, incluyendo la co-variabilidad espacial, e incorporar sesgos en presencia de forzantes climáticos como ENOS.

Palabras clave: generadores de tiempo, precipitación diaria, sesgos climáticos.

Abstract

In this study we developed a weather generator for simulating daily precipitation and evaluated its performance against data collected at 22 stations in Uruguay.

Two stochastic models were implemented, both based on a first-order, two-state Markov chain to simulate the occurrence of daily precipitation. The first model (with a total of four parameters) uses a gamma distribution to compute the nonzero daily precipitation amounts, and the second (with five parameters) uses a mixed exponential distribution. Both stationary and yearly-varying parameters were evaluated, resulting in a clear advantage for the latter. Even though the mixed exponential model has a marginally better performance than the gamma, the improvement does not justify the use of a less parsimonious model.

We then proceeded to the incorporation of ENSO-related biases in expected climate to the weather generator. In order to produce simulations consistent with a given scenario, November to January N3.4 index was selected as the conditioning variable. The results show that the proposed method successfully captures the ENSO signal. This opens interesting opportunities for the application of seasonal forecasts associated with ENSO in several sectors.

Some applications need to consider the accumulated precipitation over an extended area, which in turn requires consideration of spatial correlations. For this purpose, the single-point model was extended to a multi-point generator. Simultaneous simulation at multiple locations is achieved with a collection of individual models fed by temporally independent but spatially correlated random numbers. The results indicate that the observed statistics of rainfall are well reproduced by the simulated series. As expected, the multi-point spatial-correlated extension of the weather generator yields substantially better results.

In short, we obtained a tool for stochastic modeling of daily rainfall in Uruguay that might prove useful in various applications. It is able to reproduce the mean climate of the variable of interest (including the spatial co-variability) and to incorporate ENSO-related biases in the expected climate.

Key words: weather generators, daily precipitation, ENSO-related biases.

ÍNDICE GENERAL

AGRADECIMIENTOS.....	3
RESUMEN	5
ABSTRACT.....	7
1. INTRODUCCIÓN	15
1.1 CONTEXTO	15
1.2 OBJETIVOS.....	17
1.2.1 Generales	17
1.2.2 Específicos.....	17
1.3 CONTENIDO.....	18
2. GENERADORES DE CLIMA.....	21
2.1 MARCO TEÓRICO	21
2.1.1 Modelos de ocurrencia de precipitación	23
2.1.2 Modelos de intensidad de precipitación	26
2.1.3 Variabilidad estacional.....	29
2.2 PROGRAMAS DISPONIBLES.....	30
2.3 MODELOS IMPLEMENTADOS.....	31
2.3.1 Markov+Gamma	31
2.3.2 Markov+ExpMixta.....	33
3. DESCRIPCIÓN DE LA INFORMACIÓN EMPLEADA.....	37
3.1 INFORMACIÓN DISPONIBLE	37
3.1.1 Información geográfica	37
3.1.2 Información meteorológica	37
3.2 DISTRIBUCIÓN ESPACIAL DE ALGUNOS ESTADÍSTICOS SELECCIONADOS	46
4. ENTRENAMIENTO Y EVALUACIÓN DE LOS MODELOS IMPLEMENTADOS.....	55
4.1 ENTRENAMIENTO	55
4.1.1 Markov+Gamma	55
4.1.2 Markov+ExpMixta.....	61
4.2 EVALUACIÓN.....	62
4.2.1 Modelo anual .vs. Modelo diario	62
4.2.2 Distribución gamma .vs. Distribución exponencial mixta	66
5. INCORPORACIÓN DE SESGOS CLIMÁTICOS	85
5.1 INTRODUCCIÓN	85
5.2 CARACTERIZACIÓN DE ENOS EN URUGUAY	87
5.3 METODOLOGÍA	95
5.3.1 Estratificación por ENOS	96
5.3.1 Generación de las series sintéticas.....	96
5.4 RESULTADOS.....	96
5.5 CONCLUSIONES	105
6. CO-VARIABILIDAD ESPACIAL.....	109
6.1 ANTECEDENTES	109
6.2 METODOLOGÍA	110
6.2.1 Ocurrencia de precipitación.....	111

6.2.2	Cantidad de precipitación	113
6.3	RESULTADOS.....	114
6.4	CONCLUSIONES	115
7.	APLICACIÓN AL MODELO HIDROLÓGICO	119
7.1	SELECCIÓN DE LA CUENCA DE ESTUDIO	119
7.2	METODOLOGÍA	120
7.2.1	Generación de series sintéticas de precipitación diaria	120
7.2.2	Simulación del proceso precipitación-escorrentía	122
7.3	RESULTADOS.....	124
7.4	CONCLUSIONES	127
8.	CONCLUSIONES.....	131
9.	FUTURAS LÍNEAS DE INVESTIGACIÓN.....	137
10.	REFERENCIAS BIBLIOGRÁFICAS	141

ACRÓNIMOS

AIC	Criterio de Información de Akaike
BIC	Criterio de Información Bayesiano
DGRNR	Dirección General de Recursos Naturales Renovables
EM	Estación Meteorológica
ENOS	El Niño - Oscilación Sur
ETP	Evapotranspiración Potencial
GEI	Gases de Efecto Invernadero
INIA	Instituto Nacional de Investigación Agropecuaria
INUMET	Instituto Uruguayo de Meteorología
MGAP	Ministerio de Ganadería, Agricultura y Pesca
MVOTMA	Ministerio de Vivienda Ordenamiento Territorial y Medio Ambiente
NDE	Trimestre Nov.-Enero
RENARE	DGRNR
SIG	Sistema de Información Geográfica
SGM	Servicio Geográfico Militar
TSM	Temperatura Superficial del Mar

CAPÍTULO 1

INTRODUCCIÓN

1. Introducción

1.1 CONTEXTO

La motivación del presente trabajo tiene sus raíces en el marco de la planificación y gestión de los recursos hídricos y otros sectores que dependen de las variaciones de la precipitación. En estos ámbitos, es muy útil tener la capacidad de simular la precipitación a escala diaria, ya que es una de las variables más relevantes para muchas aplicaciones tales como el diseño de estructuras hidráulicas, estudios hidrológicos, planificación y operación de aprovechamientos que tienen como fin la provisión de agua para consumo humano y/o riego de cultivos, simulación de modelos de cultivos, simulación de sistemas eléctricos, etc.

Los ecosistemas naturales, y los sistemas productivos que sustentan, están sujetos a las variaciones del clima en muy diversas escalas de tiempo. La apropiada gestión de dichos recursos requiere de un adecuado manejo de los riesgos climáticos asociados a esta variabilidad. Dicha capacidad de gestión es clave para construir adaptabilidad frente a presiones antrópicas y a cambios en el clima (Baethgen et al., 2004).

Las herramientas de gestión suelen estar basadas en algún tipo de modelación del sistema que, si depende significativamente del clima, tendrá como uno de sus insumos series de variables meteorológicas relevantes en las escalas de tiempo de interés. Para explicar cabalmente la variabilidad climática antes mencionada, se requieren de largos períodos de información. Muchas veces esto se dificulta, ya que en general los registros históricos están incompletos o no están disponibles de una manera sencilla, pueden ser de duración insuficiente, o estar accesibles solamente en resúmenes mensuales.

Por otro lado, la gestión del riesgo requiere conocer la probabilidad de ocurrencia en el rango de resultados posibles ante diversos escenarios climáticos. Dichos escenarios, a su vez, pueden estar afectados por sesgos provenientes de predicciones climáticas asociadas, por ejemplo, al fenómeno de El Niño - Oscilación Sur (ENOS). Es aquí donde se suele producir una disociación entre la manera en que se difunden dichos pronósticos climáticos y las necesidades de información de los modelos de apoyo a la toma de decisión. Por ejemplo, la cuantificación del riesgo climático asociado a un cultivo requerirá series diarias de precipitación (y tal vez de otras variables) para hacer simulaciones con modelos específicos, mientras que los pronósticos climáticos estacionales suelen mencionar solamente sesgos en la distribución de precipitación acumulada trimestral (conflicto de escala temporal). A su vez, los mejores escenarios climáticos disponibles aún presentan un nivel de detalle en el espacio que es mucho menor que el que generalmente requiere un tomador de decisiones (conflicto de escala espacial). Esta incompatibilidad lleva a que información de valor no se use, al menos no explícitamente.

En este contexto, el desarrollo de generadores de tiempo tiene una larga tradición en diversas aplicaciones relacionadas con la posibilidad de generar series sintéticas de la longitud deseada, reproduciendo el clima medio de las variables de interés (incluyendo la co-variabilidad espacial y entre variables) e incorporando sesgos en presencia de forzantes climáticos como ENOS. La literatura sobre generadores de tiempo es extensa (Wilks y Wilby, 1999, Srikanthan et al., 2001; Baigorria et al., 2010; Maraun et al., 2010; Ailliot et al., 2014), pero la aplicación de dicho conocimiento a la realidad nacional es muy acotada (Grondona et al., 2000).

Definición: Por generadores de tiempo se refiere a procesos estocásticos entrenados para reproducir algunas propiedades estadísticas de series meteorológicas, tales como la precipitación, la temperatura y la radiación solar (Richardson, 1981; Coe y Stern, 1982; Rascko et al., 1991).

Hay muy diversos aspectos que deben ser considerados en el proceso de selección y adaptación de los modelos desarrollados internacionalmente a la realidad del país, entre los que se destaca: la disponibilidad de datos de entrenamiento (calidad, completitud, longitud, cobertura espacial), la naturaleza de la variabilidad climática en sus diferentes escalas espacio-temporales, la predictibilidad de la precipitación (asociada a ENOS) y su estacionalidad.

De esta manera, en base a la literatura internacional y al conocimiento local de nuestro clima, se desarrollará una herramienta de utilidad en

diversos sectores, fundamentalmente para la gestión de recursos naturales y productivos.

1.2 OBJETIVOS

A continuación se presentan los objetivos generales y específicos planteados en la presente tesis de maestría.

1.2.1 Generales

En vistas a las necesidades y problemas mencionados anteriormente, se planteó como objetivo general del presente estudio la elaboración de un generador estocástico de precipitación diaria capaz de reproducir el clima medio de la variable de interés, incluyendo la co-variabilidad espacial, e incorporar sesgos en presencia de forzantes climáticos como ENOS.

Se propone también la aplicación del generador de tiempo desarrollado en un modelo de uso en el país para la simulación del proceso precipitación-escorrentía de paso mensual.

1.2.2 Específicos

Para cumplir con los objetivos generales, se plantearon los siguientes objetivos específicos:

- Revisar el estado del arte en la modelación de la variable estocástica precipitación diaria.
- Formular y aplicar distintos modelos estocásticos que surjan de la literatura para la simulación de la precipitación diaria en un punto geográfico (se analizará luego la co-variabilidad espacial):
 - Explorando diversas alternativas para representar la estacionalidad de los parámetros del modelo a lo largo del año.
 - Empleando diferentes distribuciones de intensidad de precipitación para los días lluviosos.
- Entrenar y evaluar los generadores desarrollados y seleccionar el modelo más adecuado para la realidad del país.
- Incorporar al generador seleccionado sesgos climáticos, buscando que dicha herramienta sea útil para la adaptación en sistemas sujetos a riesgo climático.
- Modificar el modelo seleccionado de forma tal que preserve también las correlaciones espaciales entre los distintos puntos geográficos (modelo multipunto).

- Aplicar el generador de tiempo para el cálculo del escurrimiento mensual mediante el modelo de precipitación-escorrentía de Temez (Temez, 1977), el cual se encuentra ampliamente difundido en Uruguay.

1.3 CONTENIDO

El presente informe se divide en nueve capítulos, incluyendo este primero de introducción. En el segundo capítulo se presenta un breve marco teórico sobre la modelación estocástica de la precipitación diaria en un punto geográfico y se detallan los modelos (puntuales) implementados para el desarrollo de este trabajo. En el tercer capítulo se describe la información empleada, incluyendo la evaluación de ciertos estadísticos considerados de particular interés en el contexto de la disponibilidad hídrica, a partir de los cuales se evaluará el desempeño de los generadores implementados. El cuarto capítulo aborda el entrenamiento de los modelos en 22 puntos geográficos (por entrenamiento se refiere a la estimación de los parámetros para cada modelo y punto geográfico). Este capítulo también incluye la evaluación de la habilidad de cada modelo para reproducir determinados estadísticos de las series observadas, para luego seleccionar el modelo estocástico más adecuado para la realidad del país. En el capítulo cinco se presenta la incorporación de sesgos climáticos al modelo seleccionado anteriormente. El capítulo seis aborda la implementación del modelo multipunto, partiendo del modelo seleccionado y modificándolo de forma tal que preserve las correlaciones espaciales entre los distintos puntos geográficos. En el capítulo siete se presenta la aplicación del generador de tiempo en un modelo para la simulación del proceso precipitación-escorrentía de paso mensual. En el capítulo ocho se presentan las conclusiones de este trabajo de tesis. Por último, en el capítulo nueve se enumeran algunas de las posibles líneas de investigación a desarrollar en el futuro.

CAPÍTULO 2

GENERADORES DE CLIMA

2. Generadores de clima

A continuación se resumen los principales antecedentes reunidos sobre la modelación estocástica de la precipitación diaria y se detallan los modelos implementados para el desarrollo del presente trabajo.

2.1 MARCO TEÓRICO

Los modelos matemáticos se clasifican en dos grandes grupos: determinísticos y estocásticos. Los primeros disponen de ecuaciones analíticas basadas en relaciones causa-efecto conocidas a priori, por lo que, dado un conjunto de parámetros y variables de entrada, van a producir siempre el mismo conjunto de variables de salida. Los modelos estocásticos o probabilísticos se formulan sobre la base de la teoría de la probabilidad e incluyen generadores de procesos aleatorios de forma tal que, para un mismo conjunto de datos de entrada, las salidas no serán siempre las mismas (ya que el azar interviene en el modelo).

Un **generador de tiempo** (WG, por sus siglas en inglés: Weather Generator) es un modelo estocástico que produce series sintéticas de longitud ilimitada de una variable meteorológica (en este caso precipitación diaria) para una ubicación dada, a partir de un conjunto de estadísticos representativos del clima observado en dicho lugar. Las series generadas no corresponden a un pronóstico, si no a una condición probable aleatoria. Es decir, si bien los resultados se comportan estadísticamente como los datos observados, no se espera que ninguna serie temporal simulada en particular coincida con la serie observada en un momento dado, ya sea en el pasado o en el futuro.

La reproducción a partir de estos modelos -o al menos una buena aproximación- de la estructura espacio-temporal observada, tanto en

valores medios como en su persistencia y variabilidad, es una característica deseada para muchas aplicaciones tales como estudios hidrológicos, simulación de cultivos, simulación de sistemas eléctricos, etc.

Debido al carácter mixto discreto/continuo de la precipitación diaria, usualmente se la divide en un proceso de ocurrencia y un proceso de intensidad. De esta forma, en la mayoría de los generadores de tiempo (denominados “modelos de dos etapas”), el proceso de precipitación es modelado mediante una secuencia de dos variables aleatorias $\{(X_t, Y_t); t = 1, 2, \dots\}$, donde:

- X_t es una **variable discreta** (binaria) que representa el estado del proceso en el tiempo t , su valor es igual a 1 si la lluvia es mayor o igual que un umbral (día lluvioso) y a 0 en caso contrario (día seco).
- Y_t es una **variable continua** que representa la cantidad de lluvia en el tiempo t para un día lluvioso.

La modelación estocástica de la precipitación diaria ha sido objeto de numerosos trabajos que comenzaron en los años 60. Gabriel y Neumann (1962) propusieron el primer modelo estadístico¹ para simular la ocurrencia de precipitación diaria mediante una cadena de Markov de primer orden de dos estados. Luego, Todorovic y Woolhiser (1975) combinaron dicho modelo con una distribución exponencial para determinar la cantidad de precipitación de los días lluviosos, obteniendo de esta manera el primer generador estocástico de precipitación diaria. Otro trabajo fundamental en esta área es el de Richardson (1981), que incorporó la simulación de la radiación solar y la temperatura mínima y máxima diaria al generador desarrollado por Katz (1977a), como soporte a los modelos de crecimiento y rendimiento de cultivos.

Muchas extensiones han sido propuestas a partir de estos trabajos, las cuales fueron resumidas por tres artículos principalmente (dos publicados a principios del siglo XXI y uno aún en proceso de publicación). Wilks y Wilby (1999) hicieron una presentación detallada del modelo de Richardson y sus extensiones, con una discusión de las ventajas y desventajas de estos modelos y algunas aplicaciones. Srikanthan et al. (2001) elaboraron una lista exhaustiva de los modelos puntuales existentes para variables climáticas de paso anual, mensual y diario, y además

¹ Si bien existen algunos trabajos anteriores (Quetelet en 1852; Newnham, 1916; Besson, 1924; entre otros), generalmente se le acredita a Gabriel y Neumann (1962) la presentación del primer modelo estadístico para simular la ocurrencia de precipitación diaria.

hicieron algunas observaciones sobre los modelos multipunto. Recientemente, Ailliot et al. (2014) realizaron una puesta a punto sobre el tema, con el propósito de ayudar a los usuarios a entender los conceptos probabilísticos detrás de los generadores de tiempo e identificar sus ventajas y límites.

2.1.1 Modelos de ocurrencia de precipitación

La clase más común de modelo estocástico usado para representar las series temporales de variables discretas, tales como la ocurrencia de precipitación, es la **cadena de Markov**.

Una cadena de Markov $(X_n)_{n \geq 0}$ puede ser imaginada como una sucesión de estados de un sistema. Cada estado corresponde a uno de los elementos de la partición del espacio muestral (ε) que describe la variable aleatoria en cuestión. Para cada instante de tiempo, la cadena de Markov puede permanecer en el mismo estado o cambiarse a uno de los otros estados.

Una *cadena de Markov de orden k* tiene su estructura probabilística determinada por una matriz de probabilidades de transición, donde la probabilidad de precipitación en un día dado depende solamente del estado de precipitación (x_i) de los k días anteriores, es decir:


$$P(X_n = x_n | X_{n-1} = x_{n-1}, \dots, X_0 = x_0) = P(X_n = x_n | X_{n-1} = x_{n-1}, \dots, X_{n-k} = x_{n-k}) \\ \forall x_0, \dots, x_{n-k}, \dots, x_n \in \varepsilon$$

La identidad mostrada anteriormente es la propiedad de Markov.

La matriz de probabilidades de transición (A) queda entonces definida, entrada a entrada, como $A_{i,j} = p_{ij}$ donde $p_{ij} = P(X_n = j | X_{n-1} = i)$, es decir, la entrada i, j corresponde a la probabilidad de ir del estado i al estado j en un paso.

En el caso de la ocurrencia de precipitación se tienen dos posibles estados (lluvia, no lluvia), entonces $\varepsilon = \{0,1\}$.

A modo de ejemplo, en la Figura 2-1 se muestra la representación esquemática de una cadena de Markov de dos estados de primer orden, junto con sus cuatro probabilidades de transición.



Probabilidad de no lluvia, dado que no llovió: $p_{00} = P(X_n = 0 | X_{n-1} = 0)$

Probabilidad de lluvia, dado que no llovió: $p_{01} = P(X_n = 1 | X_{n-1} = 0)$

Probabilidad de no lluvia, dado que llovió: $p_{10} = P(X_n = 0 | X_{n-1} = 1)$

Probabilidad de lluvia, dado que llovió: $p_{11} = P(X_n = 1 | X_{n-1} = 1)$

Figura 2-1: Representación esquemática de una cadena de Markov de 2 estados, 1° orden.

Dado que las cuatro probabilidades de transición son pares de probabilidades condicionales, las mismas verifican las siguientes relaciones:

$$p_{00} + p_{01} = 1$$

$$p_{10} + p_{11} = 1$$

Por lo tanto, en este caso, es suficiente con estimar sólo dos de los cuatro parámetros del modelo (una probabilidad de cada uno de los pares de probabilidades condicionales, por ejemplo p_{01} y p_{11}).

Asumiendo que la cadena de Markov es homogénea (los elementos de la matriz A permanecen invariantes en el tiempo), el procedimiento de estimación de los parámetros consiste simplemente en el cálculo de las frecuencias relativas condicionales que producen los estimadores de máxima verosimilitud (MLE), según:

$$\hat{p}_{01} = \frac{\# \text{ de } 0's \text{ seguidos de } 1's}{\# \text{ Total de } 0's} = \frac{n_{01}}{n_0}$$

$$\hat{p}_{11} = \frac{\# \text{ de } 1's \text{ seguidos de } 1's}{\# \text{ Total de } 1's} = \frac{n_{11}}{n_1}$$

donde n_{ij} es el número de veces que la cadena pasa del estado i al estado j y n_i es el número de veces que la cadena ocupa el estado i .

La mayoría de los modelos de cadena de Markov referidos en la bibliografía son de primer orden (Gabriel y Newmann, 1962; Katz, 1977b; Richardson, 1981). Estos modelos son los más usados debido a su simplicidad y relativa facilidad para estimar sus parámetros. Los mismos logran capturar la persistencia natural de la precipitación diaria, siendo su

principal limitación la simulación de largas secuencias de días secos (rachas secas).

En general, las cadenas de Markov de orden superior suelen mejorar estas deficiencias (Chin, 1977; Coe y Stern, 1982; Wilks, 1999a). Sin embargo, requieren de la estimación de un mayor número de parámetros (una cadena de k -ésimo orden y dos estados está caracterizada por 2^k parámetros), para lo cual es necesario contar con un registro de datos de mayor longitud y resulta además en mayores incertidumbres (sobre los parámetros y sobre el modelo mismo).

Stern y Coe (1984) sugirieron, con el propósito de mejorar la reproducción de rachas secas pero sin incrementar exponencialmente el número de parámetros, el uso de *cadenas de Markov de orden híbrido*, en las que la probabilidad de precipitación en un día dado depende del estado de precipitación de los l días anteriores, donde l es el mínimo entre el número de días desde el último día lluvioso y el orden k del modelo híbrido. En efecto, estos modelos conservan la dependencia de primer orden para los días lluviosos, pero permiten aumentar la “memoria” para las rachas secas (cuando no llovió voy más días hacia atrás en el tiempo).

Para determinar el orden más apropiado de una cadena de Markov para representar una serie de datos en particular, usualmente se emplean dos criterios: el Criterio de Información de Akaike “AIC” (Akaike, 1974) y el Criterio de Información Bayesiano “BIC” (Schwarz, 1978). Ambos criterios se basan en la función de log-verosimilitud, tomando en cuenta el número de parámetros y la cantidad de información; el mejor modelo es aquel que presenta el menor valor. Los dos criterios sólo difieren en la función de penalización por el número de parámetros.

De todas maneras, la selección del orden del modelo es una tarea subjetiva ya que, si bien los criterios BIC y AIC pueden ayudar, la elección final dependerá del uso que se le vaya a dar a dicho modelo y de otros criterios como la parsimonia, la interpretabilidad, el tiempo de cómputo, la robustez y adaptabilidad. En este sentido, los modelos más simples, cuya aplicación práctica es inmediata, pueden ser más útiles que los más complejos cuya utilización tal cual es poco probable.

Un enfoque alternativo a los modelos de cadena de Markov para simular la ocurrencia de precipitación diaria son los *procesos de renovación alternativa*, también llamados modelos de longitud de rachas (Wilks, 1999a). En lugar de simular la ocurrencia de lluvia día a día, estos modelos consideran a la serie de precipitación diaria como una secuencia de alternancia de períodos lluviosos y secos de longitud variable. Los períodos lluviosos y secos se supone que son independientes y se pueden ajustar diferentes distribuciones de probabilidad a las frecuencias relativas

observadas de longitudes de rachas secas y lluviosas. Entre las distribuciones propuestas se incluyen la distribución logarítmica, la distribución binomial negativa truncada (Buishand, 1977) y la distribución geométrica truncada (Roldan y Woolhiser, 1982). Una racha de días secos de longitud k se define como la secuencia de k días secos consecutivos limitados en cada lado por un día lluvioso, y análogamente para una racha de días lluviosos. El término “renovación” deriva de la independencia entre las longitudes de rachas secas y lluviosas, mientras que el término “alternativo” se debe a la alternancia de ambos tipos de rachas.

2.1.2 Modelos de intensidad de precipitación

Una vez que se ha simulado la serie binaria de ocurrencia de precipitación diaria, se debe simular la cantidad de precipitación de los días lluviosos.

Para caracterizar la intensidad de precipitación como variable continua (considerando solamente los días en que ocurrió el evento) se debe definir una función de densidad de probabilidad. Para ello se puede suponer que la función pertenece a alguna familia paramétrica y estimar sus parámetros en base a los datos disponibles.

La característica estadística más destacable de los montos de precipitación diaria es su distribución asimétrica positiva. Es decir, los valores pequeños son muy frecuentes, mientras que los grandes montos de precipitación -importantes en muchas aplicaciones tales como la hidrología, agricultura, etc.- son relativamente poco frecuentes.

En este sentido, existe gran variedad de distribuciones continuas que están limitadas a la derecha por cero y están positivamente sesgadas.

La **distribución exponencial** es probablemente el modelo más simple para modelar los montos de precipitación diaria, ya que requiere la estimación de un solo parámetro (β) y reproduce satisfactoriamente la fuerte asimetría positiva observada. Su función de densidad de probabilidad es:

$$f(x) = \frac{1}{\beta} e^{-\frac{x}{\beta}} \text{ con } x, \beta > 0$$

El parámetro β es el valor medio de los montos de precipitación no nulos y tiene las mismas dimensiones físicas que x .

La distribución exponencial ha sido utilizada por Todorovic y Woolhiser (1975), Richardson (1981), Wilby (1994), entre otros.

Otro modelo empleado para simular la distribución de montos de precipitación diaria, dada la ocurrencia de un día lluvioso, es la **distribución gamma** de dos parámetros (α y β , parámetros de forma y escala respectivamente), cuya función de densidad de probabilidad es:

$$f(x) = \frac{(x/\beta)^{\alpha-1} e^{-\frac{x}{\beta}}}{\beta \Gamma(\alpha)} \text{ con } x, \alpha, \beta > 0$$

donde $\Gamma(\alpha)$ es la función gamma evaluada en α .

El parámetro α es adimensional y el parámetro β tiene las mismas dimensiones físicas que x .

Para $\alpha \leq 1$, la distribución está fuertemente sesgada a la derecha, con $f(x) \rightarrow \infty$ cuando $x \rightarrow 0$. Para $\alpha = 1$ la distribución gamma se reduce a la distribución exponencial. Para $\alpha > 1$, la distribución gamma comienza en el origen $f(0) = 0$. Progresivamente, mayores valores de α resultan en menos sesgo y un desplazamiento de la probabilidad de densidad a la derecha. Para valores de α muy grandes (mayores que 50 a 100) la distribución gamma se aproxima a la distribución normal en su forma (Wilks, 2006).

El rol del parámetro de escala (β) es el de alargar o estrechar la función gamma a la derecha o a la izquierda, permitiendo un acomodamiento de las frecuencias de los montos de precipitación y mejorando entonces el desempeño del modelo.

A modo de ejemplo, a continuación se presenta la representación gráfica de la distribución gamma para algunos valores de α y β .




Figura 2-2: Distribución gamma para algunos valores de α y β .

La distribución gamma es uno de los modelos más comúnmente empleados para simular la distribución de montos de precipitación diaria

dada la ocurrencia de un día lluvioso (Katz, 1977a; Stern and Coe, 1984; Wilks; 1992; Aksoy, 2000, Baigorria, 2010).

Otro modelo usualmente referido en la bibliografía es la **distribución exponencial mixta** de tres parámetros (α : parámetro de ponderación, β_1 y β_2 : parámetros de las distribuciones exponenciales). Su función de densidad de probabilidad es:

$$f(x) = \frac{\alpha}{\beta_1} e^{-\frac{x}{\beta_1}} + \frac{(1-\alpha)}{\beta_2} e^{-\frac{x}{\beta_2}}$$

$$\text{con } x > 0; 0 < \alpha \leq 1; \beta_1 \geq \beta_2 > 0$$

Dicha distribución se interpreta como una combinación probabilística de dos distribuciones exponenciales de un parámetro (β_1 y β_2), la primera se muestra con probabilidad α y la segunda se utiliza con una probabilidad $1 - \alpha$.

El parámetro α es adimensional y los parámetros β_1 y β_2 tienen las mismas dimensiones físicas que x .

La condición $\beta_1 \geq \beta_2$ no es matemáticamente necesaria, pero se impone a los efectos de facilitar su interpretación y representación gráfica.

Para $\beta_1 = \beta_2$ o $\alpha = 1$ o $\alpha = 0$, la distribución se reduce a la distribución exponencial de un parámetro.

La distribución exponencial mixta fue empleada por primera vez para simular la distribución de montos de precipitación diaria por Woolhiser y Pegram (1979). Luego, diversos autores llegaron a que dicha distribución presenta un desempeño sustancialmente superior que la distribución gamma (Woolhiser y Roldan, 1982; Wilks, 1998; Wilks, 1999a; Wilks y Wilby, 1999; Detzel, 2011).

La mayoría de los generadores de tiempo suponen que los montos de precipitación en los días lluviosos son independientes e idénticamente distribuidos (*iid*). Dicha suposición significa que la correlación día a día entre las cantidades de precipitación diaria (sin incluir los días secos) es igual a cero, y la misma distribución es aplicable a todos los días.

Katz (1977a) y Wilks (1999a) consideraron diferentes distribuciones para la cantidad de precipitación en función de la posición del día en una racha lluviosa (por ejemplo, la precipitación media en un día lluvioso después de un día lluvioso podría ser mayor que en un día lluvioso después de un día seco), llegando a que no había diferencias apreciables en los resultados en comparación a la suposición de *iid*.

Otro enfoque para incluir la correlación entre los montos de precipitación distintos de cero es el uso de *cadena de Markov de múltiples estados* (más de

dos estados). Estos modelos simulan tanto la ocurrencia como la intensidad de precipitación diaria mediante la definición de rangos de cantidad de precipitación que constituyen los distintos estados (Gregory et al., 1993). La validez de este enfoque se basa claramente en la elección del número de estados y sus rangos (umbrales de precipitación) y en las distribuciones utilizadas para modelar la cantidad de precipitación en un día lluvioso en cada estado. Estos modelos implican un gran número de parámetros (comparativamente), y por lo tanto requieren de largos registros de datos.

2.1.3 Variabilidad estacional

Una de las características más importantes del proceso de precipitación es su variabilidad estacional, junto con una posible variabilidad interanual y en escalas aún más largas.

Varios enfoques se han ocupado de la estacionalidad, en el supuesto de que los parámetros del modelo varían a lo largo del año, pero la forma de considerarla varía notablemente (Coe y Stern, 1982).

Una opción es estimar independientemente los parámetros para períodos de tiempo oscilando entre unos pocos días y varios meses y suponer que durante esos períodos los mismos permanecen constantes (Richardson y Wright, 1984; Wilks, 1999a), pero ello conduce a un gran número de parámetros con pequeñas muestras para ajustar el modelo. Teniendo en cuenta que en un registro de N años sólo se dispone de N datos de precipitación para cada día, este número resulta estadísticamente insuficiente aún disponiendo de registros considerados como largos (30 o 40 años). Por lo tanto, otra opción consiste en agrupar los datos en *períodos móviles de n días* y calcular los parámetros para cada período, suponiendo que se mantienen constantes dentro de los mismos.

Otro método frecuentemente empleado para incorporar la variación intra-anual de los parámetros son las funciones periódicas tales como las *series de Fourier finitas*, ajustadas por mínimos cuadrados o mediante estimaciones directas por máxima verosimilitud (Woolhiser y Pegram, 1979).

Como alternativa, se pueden emplear *cadena de Markov no homogéneas* (no estacionarias) de manera de capturar los ciclos y tendencias (Rajagopalan et al., 1996).

A su vez, también es posible introducir variables climáticas globales o índices climáticos (como por ejemplo el ENOS) en el mecanismo de variación de los parámetros. Por lo general, esto mejora la reproducción de la variabilidad interanual y ofrece una forma de vincular los generadores

de tiempo (locales) con los modelos climáticos globales, dando paso a los llamados métodos de *downscaling* o métodos de reducción de escala (Maraun et al., 2010; Wilks, 2010; Wilks 2012).

2.2 PROGRAMAS DISPONIBLES

En la actualidad existe gran variedad de paquetes de software disponibles para la generación estocástica de variables meteorológicas. Desde que en el año 1981 Richardson desarrollara el modelo WGEN, han surgido posteriormente diversos generadores de tiempo entre los que destacan CLIGEN, LARS-WG, CLIMGEN (versión modificada de WGEN), entre otros.

En la Tabla 2-1 se presentan brevemente las características de los modelos de precipitación diaria de los generadores de tiempo con mayor repercusión.

Tabla 2-1: Estructura del modelo de precipitación diaria de algunos generadores de tiempo (Tabla adaptada de Hussain, 2008)

Modelo	Ocurrencia	Intensidad	Referencia
WGEN	Cadena de Markov de primer orden con probabilidades de transición mensuales.	Distribución gamma de dos parámetros. Umbral: 0 mm	Richardson and Wright (1984)
LARS-WG	Alternancia de períodos lluviosos y secos de longitud variable a partir de distribuciones semi-empíricas.	Distribución semi-empírica. Umbral: 0 mm	Rascko et al. (1991) Semenov y Barlow (1997)
USCLIMATE	Cadena de Markov de primer orden con probabilidades de transición mensuales.	Distribución exponencial mixta de tres parámetros. Umbral: 0,25 mm	Hanson et al. (1994)
CLIGEN	Cadena de Markov de primer orden con probabilidades de transición mensuales.	Distribución normal asimétrica de dos parámetros.	Nicks y Gander (1994)
CLIMGEN	Cadena de Markov de primer orden con probabilidades de transición mensuales.	Distribución weibull de dos parámetros.	Campbell (1990)

Si bien la mayoría de dichos modelos han sido evaluados en múltiples partes del mundo, con una gran diversidad climática, al momento de seleccionar un modelo en particular se deben estudiar detalladamente las

características de cada uno, con el objetivo de seleccionar el que mejor se ajuste al clima local y a la aplicación deseada.

2.3 MODELOS IMPLEMENTADOS

En base a la bibliografía consultada se optó por implementar los siguientes dos modelos para la simulación de la precipitación diaria en un punto geográfico (se analizará luego la co-variabilidad espacial, ver capítulo 6).

En todos los casos se asumió un umbral de precipitación de 0 mm, es decir, un día es calificado como lluvioso si la precipitación acumulada en ese día es superior a 0 mm. Como se verá más adelante, esta elección plantea exigencias sobre la calidad de la base de datos, en particular que no se confundan los días con muy poca y nula precipitación.

2.3.1 Markov+Gamma

En primer lugar se seleccionó un modelo de paso diario de cuatro parámetros (denominado “Markov+Gamma”).

Una cadena de Markov homogénea de primer orden sorteá las transiciones entre dos estados posibles (lluvia, no lluvia), para lo cual se requieren dos parámetros que coinciden con las probabilidades de que llueva condicionales a que llovió o no llovió el día anterior (p_{01} y p_{11} respectivamente).

Una vez decidido si el día es o no lluvioso se sorteá la cantidad de precipitación (asumida *iid* para todos los días del año) a partir de una distribución gamma de dos parámetros α y β , parámetros de forma y escala respectivamente.

Estimación de parámetros

Los cuatro parámetros del generador Markov+Gamma fueron estimados mediante el método de máxima verosimilitud.

En lo que respecta a la variación estacional, este modelo fue implementado en dos modalidades:

- Suponiendo que los parámetros son estacionarios a lo largo del año, es decir considerando un único set de parámetros para cada punto, usando toda la serie de datos disponible (“Modelo anual”).
- Incorporando el ciclo medio anual de los parámetros, es decir considerando un valor para cada parámetro para cada día del año y para cada punto geográfico (“Modelo diario”). Para ello, se consideró una ventana móvil centrada de +/- 30 días y se asignó a

cada día del año el valor del muestreo de los 30 días anteriores y posteriores.

En el capítulo 4.1.1 se presenta un análisis de sensibilidad a la longitud de la ventana de muestreo.

Simulación

El algoritmo empleado en este caso para la simulación estadística consiste en un *generador de números pseudo-aleatorios*, ya que si bien su salida parece ser al azar, las operaciones aritméticas realizadas por el mismo son totalmente deterministas. Basta reiniciar el generador con la misma semilla ("seed"), para reproducir exactamente la secuencia de números "aleatorios" resultante; lo cual permite la ejecución controlada de los experimentos numéricos. Dicho algoritmo fue implementado en la plataforma MATLAB.

A continuación se describen los pasos necesarios para la generación de las series sintéticas de precipitación diaria una vez determinados los parámetros del modelo.

1. Para cada día simulado (t), un número aleatorio u se sortea del intervalo $[0,1]$ a partir la distribución uniforme ($f(u) = 1, 0 \leq u \leq 1$), de manera que cualquier número real en ese intervalo es equiprobable de ser sorteado.
2. Una vez que el número aleatorio u se ha generado:
 - Si el día anterior ($t - 1$) es seco y $u \leq p_{01}$, entonces el día t es lluvioso y se procede a generar el monto de precipitación para ese día. De lo contrario, el día t será seco y el proceso se reinicia en el paso 1.
 - Si el día anterior ($t - 1$) es lluvioso y $u \leq p_{11}$, entonces el día t es lluvioso y se procede a generar el monto de precipitación para ese día. De lo contrario, el día t será seco y el proceso se reinicia en el paso 1.
3. Si el paso 2 determinó que t es un día lluvioso, se sortea un número aleatorio de distribución gamma con parámetros α y β (a partir de la transformación de variables aleatorias uniformes).

En la Figura 2-3 se presenta el diagrama de flujo del algoritmo de simulación de la precipitación diaria a través del modelo Markov+Gamma.

Cabe destacar que, en este caso, para generar el primer día de la serie se usó una probabilidad de 0,5. Si, en cambio, para el sorteo inicial se hubiera

tenido en cuenta la proporción de días lluviosos y secos observados, también se necesitaría conocer p_0 (probabilidad de no lluvia).

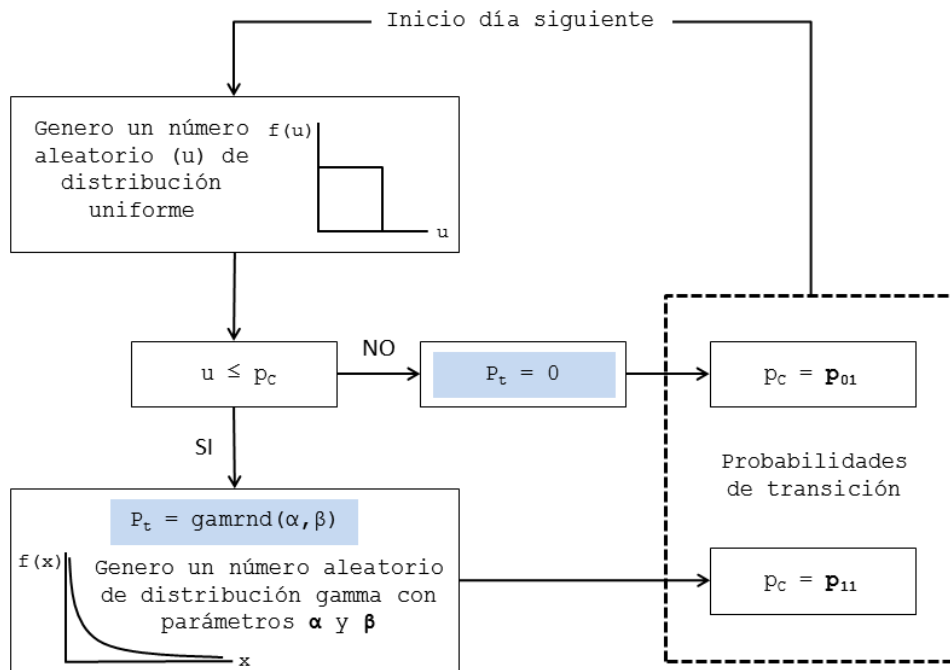


Figura 2-3: Diagrama de flujo del modelo Markov+Gamma.

2.3.2 Markov+ExpMixta

Se consideró un segundo generador estocástico de precipitación diaria denominado “Markov+Exp.Mixta”, de cinco parámetros, que difiere en el método para determinar la cantidad de precipitación de los días lluviosos.

Una vez decidido si el día es o no lluvioso mediante una cadena de Markov homogénea de primer orden y dos estados, se sortea la cantidad de precipitación de los días lluviosos (suposición *iid*) a partir de una distribución exponencial mixta de tres parámetros (α : parámetro de ponderación, β_1 y β_2 : parámetros de las distribuciones exponenciales).

Estimación de parámetros

Los cinco parámetros del generador Markov+Exp.Mixta fueron estimados mediante el método de máxima verosimilitud.

Este modelo fue implementado considerando parámetros variables a lo largo del año, con procedimiento análogo al explicado para el generador Markov+Gamma (“Modelo diario”).

Simulación

El procedimiento de simulación es análogo al del modelo Markov+Gamma, sólo difiere en el paso 3.

En la Figura 2-4 se presenta el diagrama de flujo del algoritmo de simulación de la precipitación diaria a través del modelo Markov+Exp.Mixta.

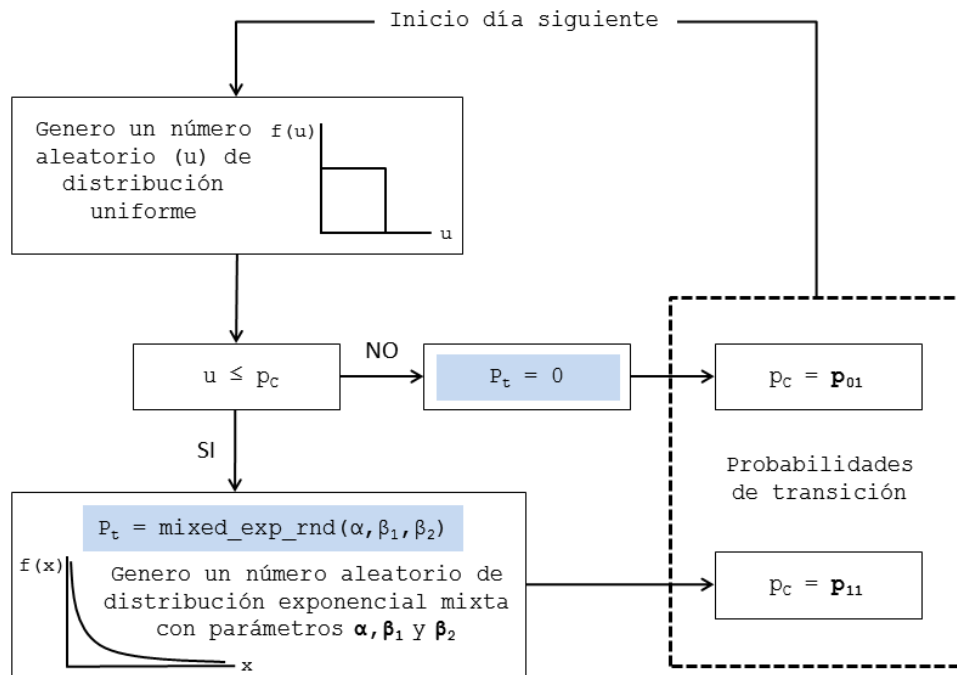


Figura 2-4: Diagrama de flujo del modelo Markov+ Exp.Mixta.

CAPÍTULO 3

DESCRIPCIÓN DE LA INFORMACIÓN EMPLEADA

3. Descripción de la información empleada

A continuación se describe la información geográfica y meteorológica utilizada para el desarrollo del presente estudio.

3.1 INFORMACIÓN DISPONIBLE

3.1.1 Información geográfica

Se contó con la siguiente información geográfica del país, a partir de la cual se generó un sistema de información geográfica (SIG) que se utilizó como plataforma de trabajo para la realización de los cálculos de superficie, agrupamiento e interpolación espacial:

- Límites departamentales.
- Cursos y cuerpos de agua.
- Estaciones pluviométricas y meteorológicas del Instituto Uruguayo de Meteorología (INUMET) y el Instituto Nacional de Investigación Agropecuaria (INIA).
- Mapa de isolíneas de evapotranspiración potencial (ETP) media anual mensual extraído del “Manual de Diseño y Construcción de Pequeñas Presas” (MVOTMA, 2011).

3.1.2 Información meteorológica

Se dispuso de registros pluviométricos diarios en 198 estaciones del INUMET y el INIA, con período de registro variable entre los años 1971 y 2011.

En función de la variabilidad del período de registro, se definió **1981 - 2009** como el período de estudio, por presentar la mayor cantidad de datos simultáneos.

Para evaluar la calidad de la información disponible, para cada estación con registros en dicho período, se identificaron los datos faltantes, se detectó la presencia de datos anómalos, se calcularon los acumulados anuales y la precipitación media anual. Además, en algunos casos, se aplicó el Método de Doble Masa para evaluar la consistencia entre estaciones cercanas.

Como resultado del análisis exploratorio, se seleccionaron 50 estaciones para la realización de este trabajo (28 estaciones pluviométricas y 22 meteorológicas), con un porcentaje de datos faltantes del orden del 1% en todos los casos. En la Figura 3-1 se muestra su distribución espacial (inhomogénea) y en la Tabla 3-1 se presentan sus coordenadas geográficas y el tipo de estación.

También se dispone para algunas estaciones (Artigas, Paysandú, Mercedes, La Estanzuela, Melo, y Rocha) de series largas de precipitación diaria (desde 1950), que serán necesarias para tener una cobertura temporal mayor y -en particular- un mayor muestreo condicionado a ENOS (ver capítulo 5).

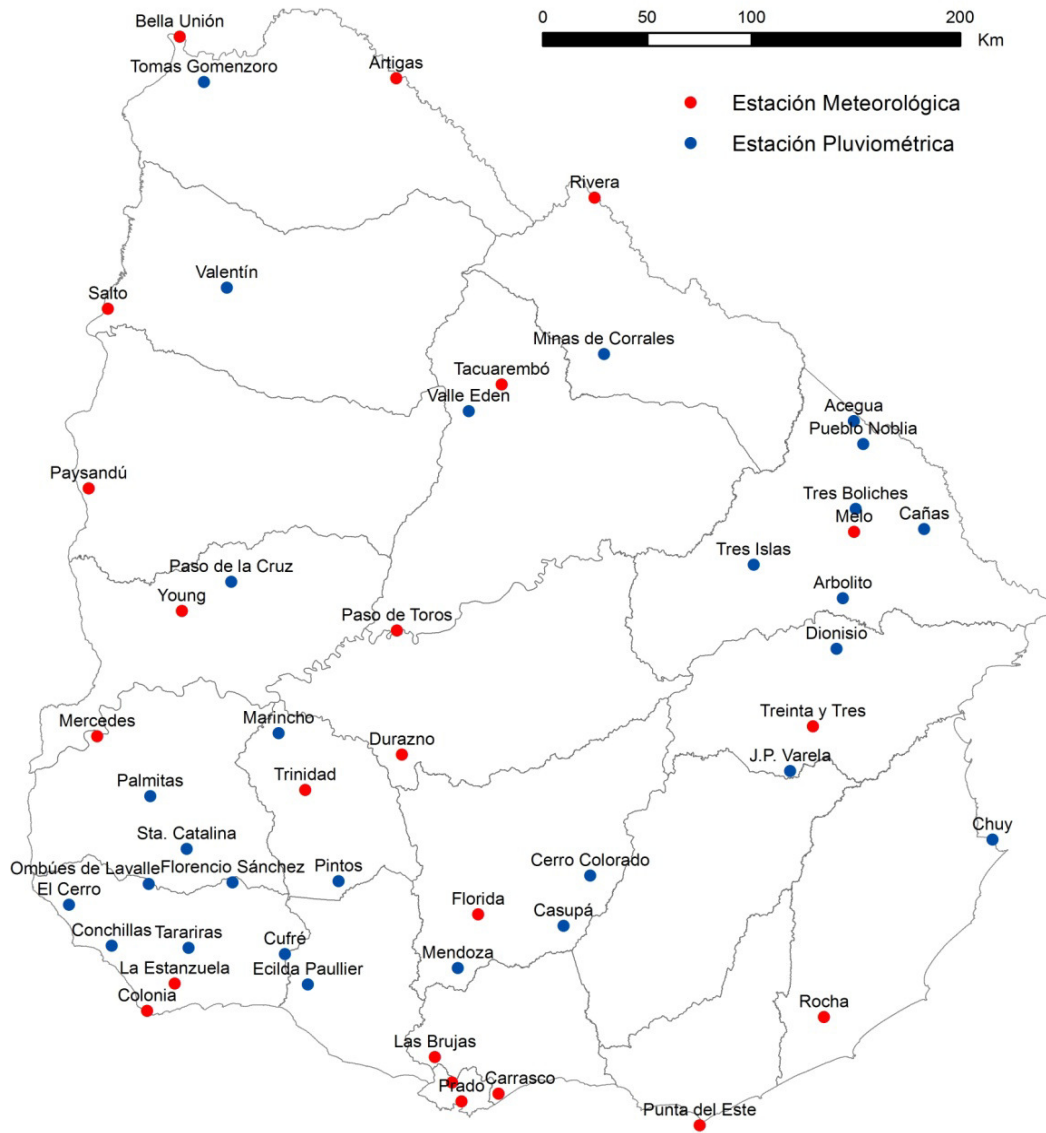


Figura 3-1: Distribución espacial de las estaciones seleccionadas.

Tabla 3-1: Ubicación de las estaciones seleccionadas.

Nº	Código	Localidad	Tipo	Latitud	Longitud
1	1013	Bella Unión	EM	-30,20	-57,58
2	1040	Tomás Gomensoro		-30,40	-57,47
3	1050	Artigas	EM	-30,39	-56,51
4	1232	Valentín		-31,30	-57,37
5	1283	Salto	EM	-31,38	-57,97
6	1405	Tacuarembó	EM	-31,73	-55,98
7	1440	Valle Eden		-31,85	-56,15
8	1672	Paysandú	EM	-32,17	-58,08
9	1709	Melo	EM	-32,37	-54,19
10	1766	Paso de la Cruz		-32,59	-57,37
11	1856	Young	EM	-32,71	-57,62
12	1914	Paso de Toros	EM	-32,81	-56,52
13	1983	Dionisio		-32,88	-54,27
14	2145	Mercedes	EM	-33,25	-58,07
15	2154	Marincho		-33,25	-57,13
16	2179	Treinta y Tres	EM	-33,22	-54,39
17	2206	Durazno	EM	-33,35	-56,50
18	2272	J.P. Varela		-33,42	-54,50
19	2297	Trinidad	EM	-33,50	-57,00
20	2289	Palmitas		-33,52	-57,80
21	2422	Chuy		-33,70	-53,45
22	2486	Pintos		-33,90	-56,83
23	2498	Cerro Colorado		-33,88	-55,53
24	2583	Florida	EM	-34,05	-56,11
25	2774	Colonia	EM	-34,45	-57,84
26	2804	Rocha	EM	-34,49	-54,31
27	2887	Prado	EM	-34,87	-56,20
28	2889	Carrasco	EM	-34,83	-56,01
29	2906	Punta del Este	EM	-34,97	-54,95
30	LE	La Estanzuela	EM	-34,34	-57,69
31	LB	Las Brujas	EM	-34,67	-56,34
32	1496	Aceguá		-31,88	-54,20
33	1537	Pueblo Noblia		-31,98	-54,15
34	1665	Tres Boliches		-32,27	-54,18
35	1712	Cañas		-32,35	-53,83
36	1792	Tres Islas		-32,52	-54,70
37	1841	Arbolito		-32,66	-54,24
38	2476	Ombúes de Lavalle		-33,90	-57,82
39	2480	Florencio Sánchez		-33,90	-57,38
40	2520	El Cerro		-33,98	-58,23
41	2611	Conchillas		-34,17	-58,02
42	2657A	Tarariras		-34,18	-57,62
43	2662A	Cufré		-34,22	-57,12
44	2670	Mendoza		-34,28	-56,22
45	2588A	Casupá		-34,10	-55,67
46	2867	Melilla	EM	-34,78	-56,25
47	1147	Rivera	EM	-30,92	-55,52
48	1374	Minas de Corrales		-31,60	-55,47
49	2704	Ecilda Paullier		-34,35	-57,00
50	2430	Sta. Catalina		-33,75	-57,62

Algunas consideraciones

Tal como se mencionó anteriormente, 22 de las 50 estaciones seleccionadas son meteorológicas, mientras que las 28 restantes corresponden a estaciones de la red pluviométrica nacional.

La diferencia entre las estaciones meteorológicas y las pluviométricas es que, además de que en las primeras se miden otras variables atmosféricas como la temperatura, presión, humedad, etc., el personal cuenta con capacitación específica. Mientras que en la red pluviométrica, los pluviómetros se encuentran ubicados en diferentes seccionales policiales del interior del país y son operados por el personal policial. A su vez, en general dicha red no cuenta con un mantenimiento periódico del instrumento, lo cual podría influir en las series analizadas.

En este sentido, Amiel et al. (2012) describió los principales problemas a enfrentar al trabajar con estaciones pluviométricas en Uruguay.

- La información proveniente de la red pluviométrica nacional es informada telefónicamente al INUMET en forma diaria. Hasta enero de 2011, dicha información era transmitida solamente cuando había registro de precipitación, ingresándola en un archivo no secuencial. El problema detectado consiste entonces en que no se distingue entre lo que se puede calificar como "dato faltante" y 0 "no lluvia", información que es conceptualmente muy distinta. Esto genera una complicación importante para el estudio por ejemplo de largas secuencia de días secos.
- Otro problema que se puede presentar es la asignación de varios días de lluvia a tan sólo uno. Esto afecta el estudio de eventos lluviosos (se genera un falso evento de lluvia intensa), repercutiendo también en la caracterización de rachas secas y en el cálculo de la frecuencia de días lluviosos.
- La distribución de los pluviómetros no es uniforme en todo el país. Es muy importante, a la hora de interpolar espacialmente un dato, contar con información confiable en estaciones cercanas.

A continuación se presentan algunas medidas de interés, calculadas para cada una de las estaciones seleccionadas, tendientes a evaluar dichos problemas.

En primer lugar se calculó la frecuencia de días de lluvia, definida como el porcentaje de valores positivos ($P > 0 \text{ mm}$) sobre el total de días de la serie. En la Figura 3-2 se presenta la frecuencia obtenida para cada estación, diferenciando entre las meteorológicas (puntos rojos) y las pluviométricas (puntos azules); cada estación tiene asociado un número de identificación

según la Tabla 3-1. En la Figura 3-3 se presenta la distribución espacial de los valores obtenidos.

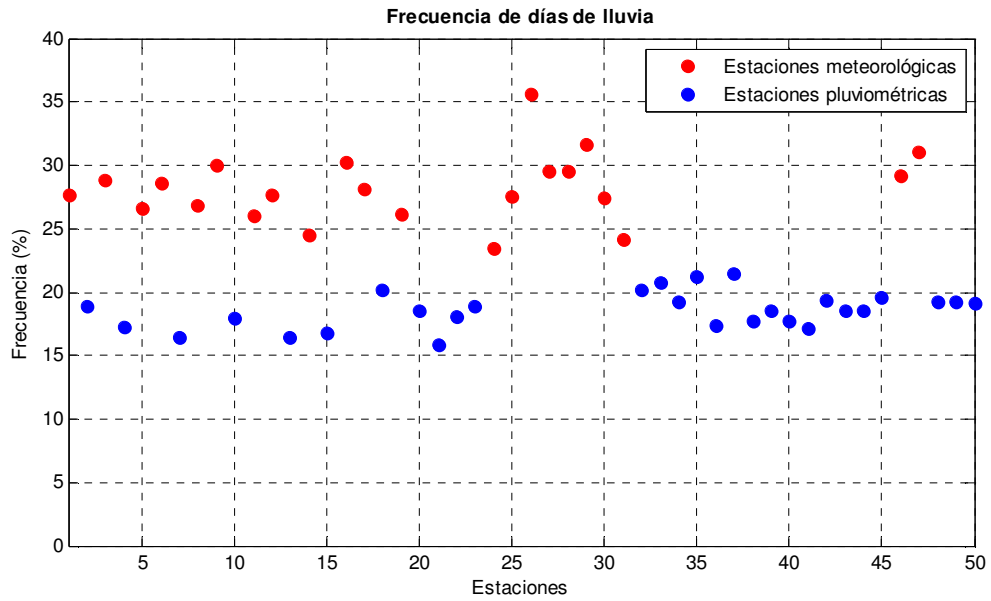


Figura 3-2: Frecuencia de días de lluvia para cada estación.

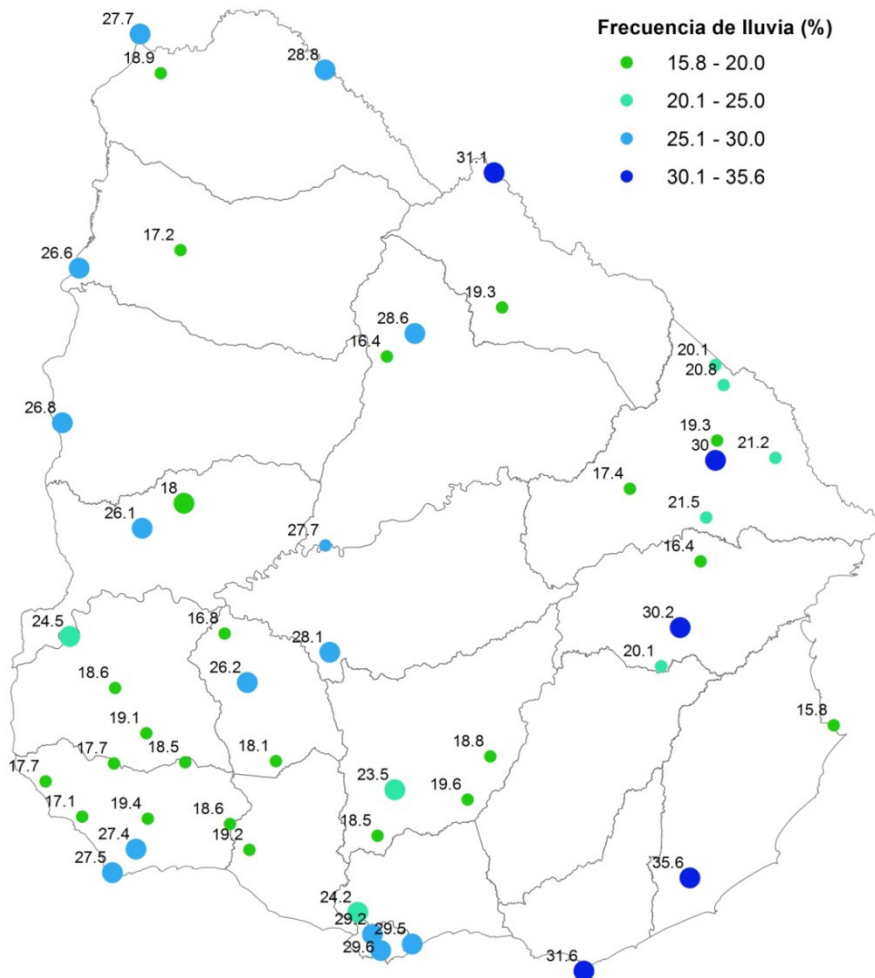


Figura 3-3: Mapa de frecuencia de días de lluvia (%)
(Puntos chicos: estaciones pluviométricas; Puntos grandes: estaciones meteorológicas)

Se observa que las estaciones pluviométricas presentan sistemáticamente menor frecuencia de días de lluvia que las meteorológicas (18,6% versus 28,2% en promedio). Con respecto a su distribución espacial, si solamente se consideran las estaciones meteorológicas, se distingue una tendencia creciente de noroeste a sureste.

Esta medida sirve para identificar a priori estaciones pluviométricas con posibles datos faltantes (debido al llenado con ceros de los períodos entre lluvias). Aquellas estaciones con muy baja frecuencia de días de lluvia (o, lo que es lo mismo, con alto porcentaje de días secos) conllevan a una cierta incertidumbre acerca de la veracidad de los datos. Cuando no hubo registro de precipitación, a priori se supuso que no llovió. Si una estación tiene una baja frecuencia de días de lluvia, esto puede deberse a que en realidad cierta parte de los datos faltantes podrían estar enmascarados como días secos, y/o también podría deberse al problema de la asignación de varios días de lluvia a uno sólo.

Luego, se construyó el mapa de la precipitación media anual registrada en cada estación durante el período de estudio (1981-2009).

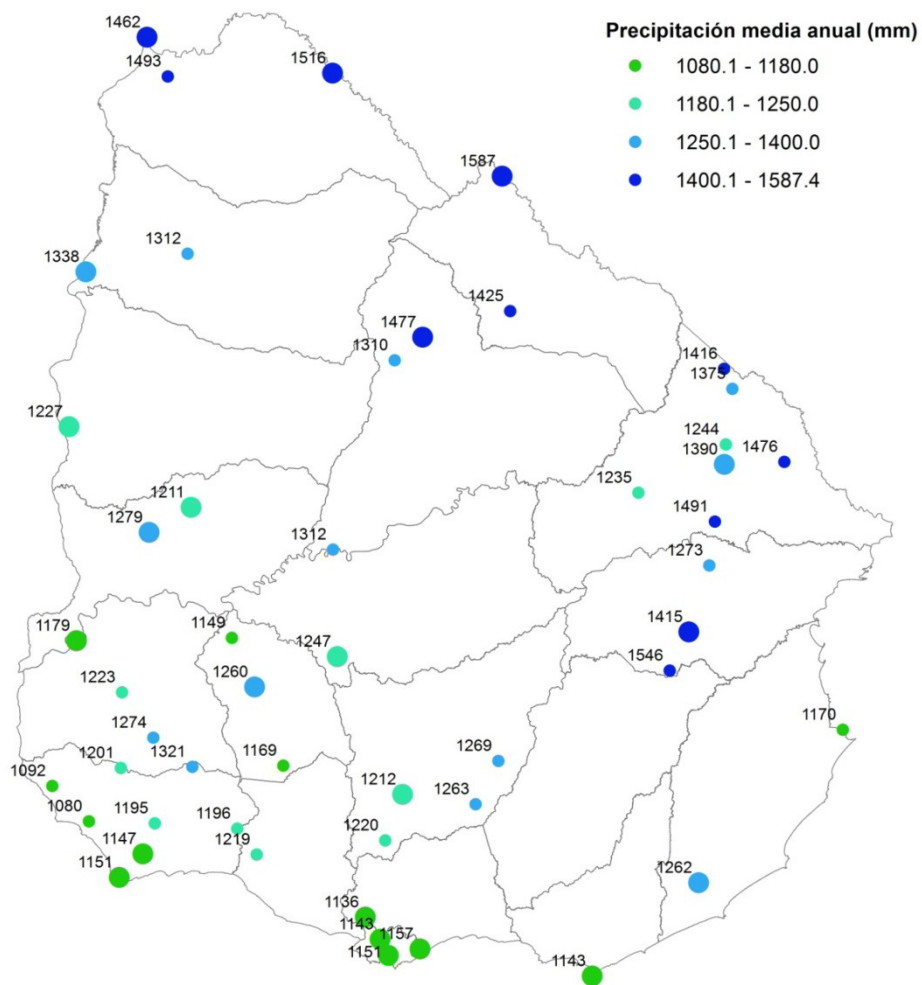


Figura 3-4: Mapa de precipitación media anual (mm)
 (Puntos chicos: estaciones pluviométricas; Puntos grandes: estaciones meteorológicas)

Los valores medios de precipitación acumulada anual obtenidos se sitúan entre 1100 y 1500 mm, con los menores valores situados al suroeste (departamento de Colonia) y los máximos al noreste (departamentos de Rivera y Artigas). El gradiente por lo tanto es de suroeste a noreste. Estos resultados son coincidentes con los presentados por INIA (2011).

Por el contrario que con la frecuencia de días de lluvia, en el caso de la precipitación media anual no se observan diferencias significativas entre las estaciones meteorológicas y pluviométricas. Por lo tanto, pareciera que las bajas frecuencias de días de lluvia en las estaciones pluviométricas no se deben a datos faltantes enmascarados como días secos (o al menos de eventos de lluvia intensa), sino a la asignación de varios días de lluvia a uno sólo (“llueve lo mismo, pero acumulado”).

En este sentido, a partir de la precipitación media anual y el número medio de días de lluvia al año, se halló la cantidad de precipitación por día de lluvia para cada estación. En la Figura 3-5 se presentan los resultados obtenidos, cada estación tiene asociado un número de identificación según la Tabla 3-1.

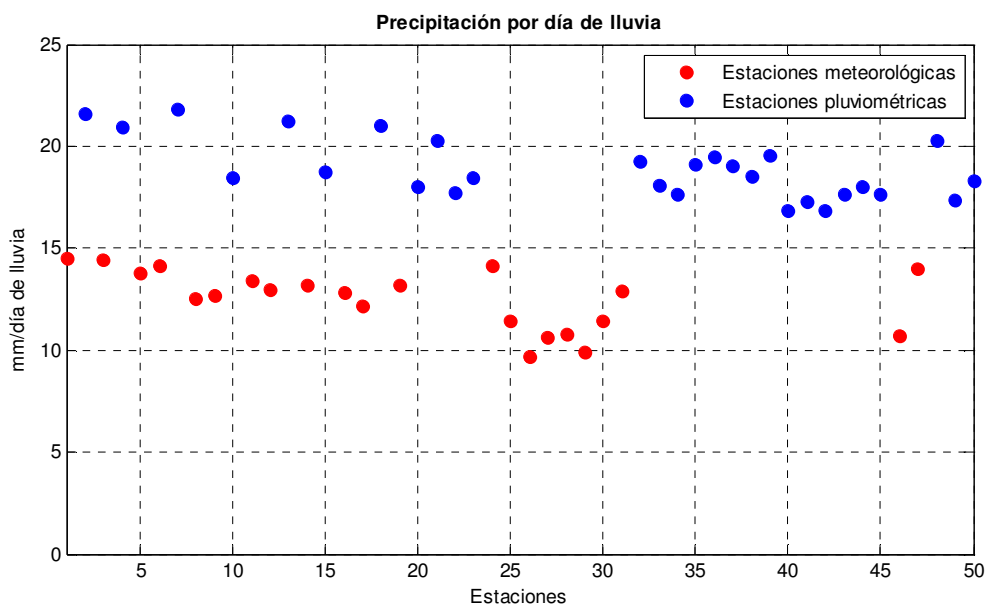


Figura 3-5: Cantidad de precipitación por día de lluvia para cada estación.

Se observa que las estaciones pluviométricas presentan sistemáticamente mayor cantidad de precipitación por día de lluvia que las meteorológicas (18,9 mm versus 12,5 mm en promedio). Esto afirma la hipótesis de que las bajas frecuencias de días de lluvia en las estaciones pluviométricas se deben a la asignación de varios días de lluvia a uno sólo y/o a que tienen una menor representación de días con muy poca lluvia.

Finalmente, se construyó el scatterplot del parámetro β_2 de la distribución exponencial mixta en función de la frecuencia de días de lluvia. Si bien el modelo Markov+Exp.Mixta fue implementado considerando parámetros variables a lo largo del año (ver capítulo 4.1), a los efectos de la construcción de este scatterplot se calculó un único valor de β_2 para todo el año para cada punto ("Modelo anual").

Cabe recordar que $\beta_1 \geq \beta_2$, por lo que β_2 es la media de la distribución exponencial que mejor se ajusta a los pequeños montos de precipitación diaria más frecuentes (rama izquierda de la función de densidad).




Figura 3-6: Parámetro β_2 (de la distribución exponencial mixta) versus la frecuencia de días de lluvia para cada estación.

Se observa que las estaciones meteorológicas -con mayor frecuencia de lluvia- son las que presentan menor β_2 (por debajo de 5 mm), con un valor medio de 1,47 mm. Las restantes estaciones tienen β_2 mayor a 12 mm, con una media de 16,36 mm. Lo cual, nuevamente deja en evidencia la falta de casos con bajos montos de precipitación en las estaciones pluviométricas.

En función de lo anterior, para entrenar y validar los modelos implementados en el presente trabajo de tesis se considerarán solamente las estaciones meteorológicas. Si bien los montos de precipitación son muy semejantes en las pluviométricas, presentan diferencias sutiles que afectan a los parámetros del generador de tiempo por lo que no es conveniente incluirlas.

3.2 DISTRIBUCIÓN ESPACIAL DE ALGUNOS ESTADÍSTICOS SELECCIONADOS

A continuación se presenta la distribución espacial de ciertos estadísticos, considerados de particular interés en el contexto de la disponibilidad hídrica, a partir de los cuales en el capítulo 4.2 se evaluará el desempeño de los generadores implementados.

En base al valor de los estadísticos determinados en cada punto, se construyeron mapas para todo el Uruguay mediante el método de interpolación Kriging Ordinario (implementado en un SIG). Dicho método se basa en cálculos de autocorrelación entre los valores de todos los puntos de la muestra, y considera además la proximidad entre los mismos, entendiéndose por tanto aplicable a parámetros tales como la precipitación y temperatura en una región de escaso relieve como la nuestra.

En primer lugar, en la Figura 3-7, se presenta el mapa de la precipitación media anual, donde nuevamente se observa una tendencia creciente de suroeste a noreste.

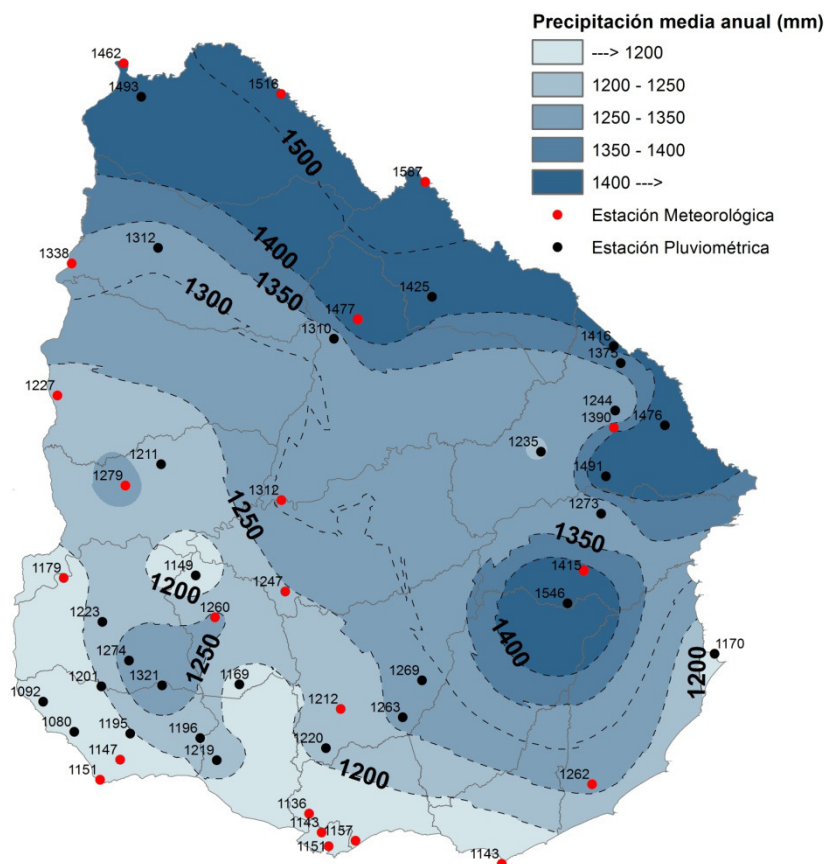


Figura 3-7: Mapa de precipitación media anual (mm).

Luego se seleccionaron los siguientes estadísticos, para caracterizar eventos de corta duración de exceso y déficit hídrico:

- **Eventos lluviosos:** se configura un evento si el acumulado de 3 días es mayor o igual a 100 mm.

Cabe destacar que la selección de este estadístico tiene la virtud de que no se ve afectado por el problema de asignación de varios días de lluvia a uno sólo.

- **Rachas secas:** se define una racha seca como el conjunto de días consecutivos en que el acumulado no supera 10 mm.

Por su parte este estadístico no se ve seriamente afectado por el problema detectado de menor frecuencia de registro de días con muy bajos montos de precipitación en las estaciones pluviométricas.

Para los eventos lluviosos se evaluó la precipitación máxima acumulada en un evento (Figura 3-8) y el período de retorno en meses entre eventos (Figura 3-9), calculado como el número total de meses sobre el de número de eventos identificados en todo el período de registro. En ambas figuras se observa la existencia de un gradiente de sur a norte, el cual es consistente con la tendencia a mayores montos de precipitación mencionada anteriormente.

Para las rachas secas se mapeó el período de retorno en meses de rachas con una longitud mayor a 20 y 30 días (Figura 3-10 y Figura 3-11 respectivamente), calculado con procedimiento análogo al explicado para los eventos lluviosos. Se observa que las regiones con menor período de retorno de rachas secas de longitud mayor a 30 días son la región centro-este y suroeste, siendo más infrecuentes hacia el sureste y noroeste del país. En el caso de las rachas mayores a 20 días, existe un patrón espacial muy similar pero con menores diferencias relativas en los valores.

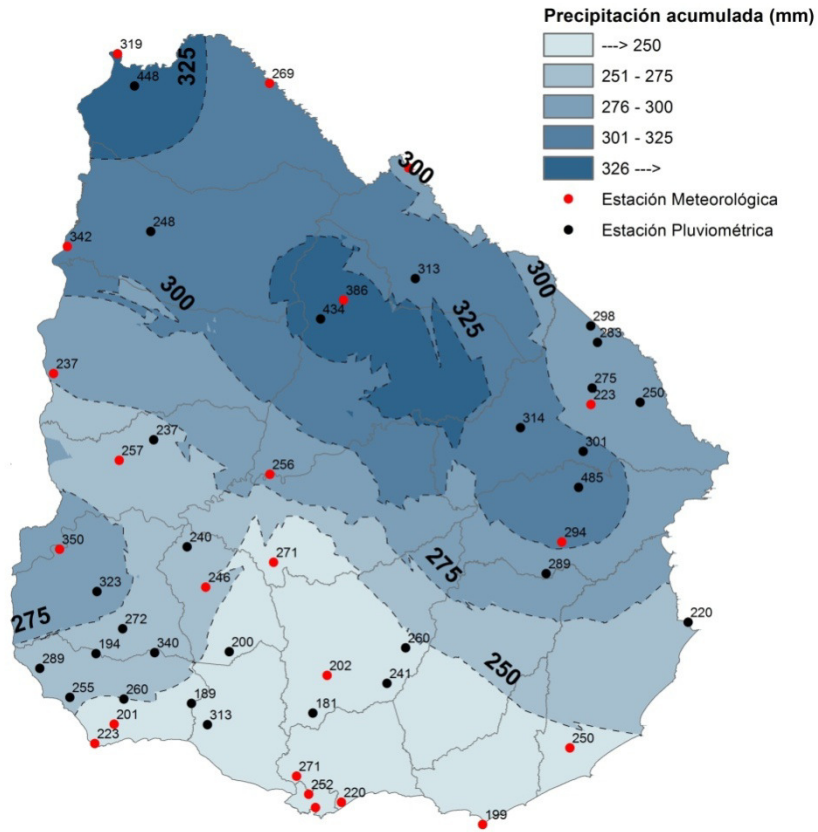


Figura 3-8: Mapa de la precipitación máxima acumulada en un evento lluvioso (mm).

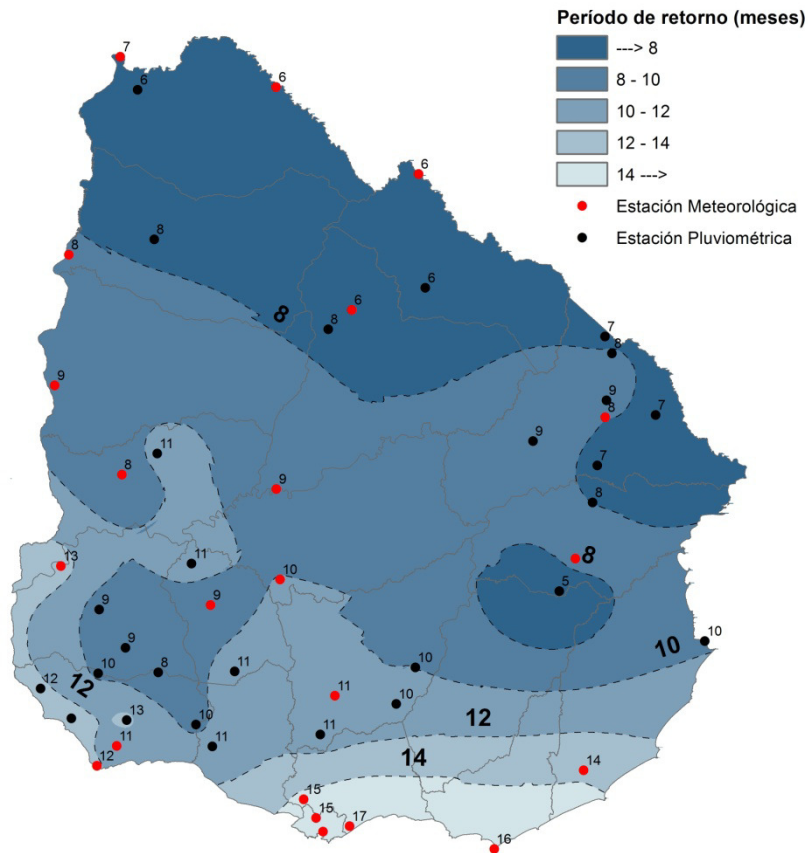


Figura 3-9: Mapa del período de retorno (meses) entre eventos lluviosos.

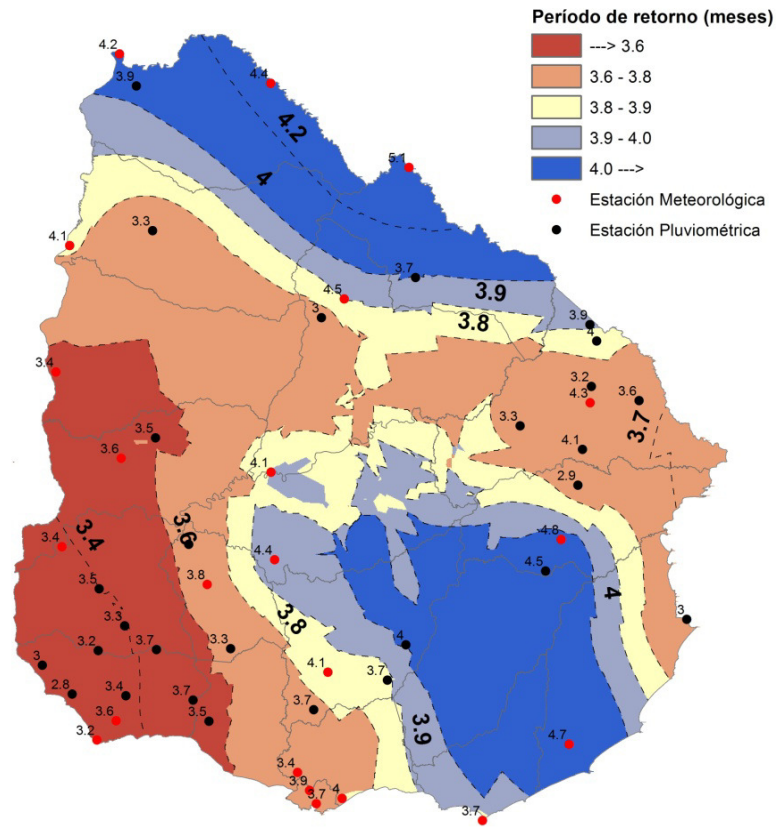


Figura 3-10: Mapa del período de retorno (meses) de rachas secas con una longitud mayor a 20 días.

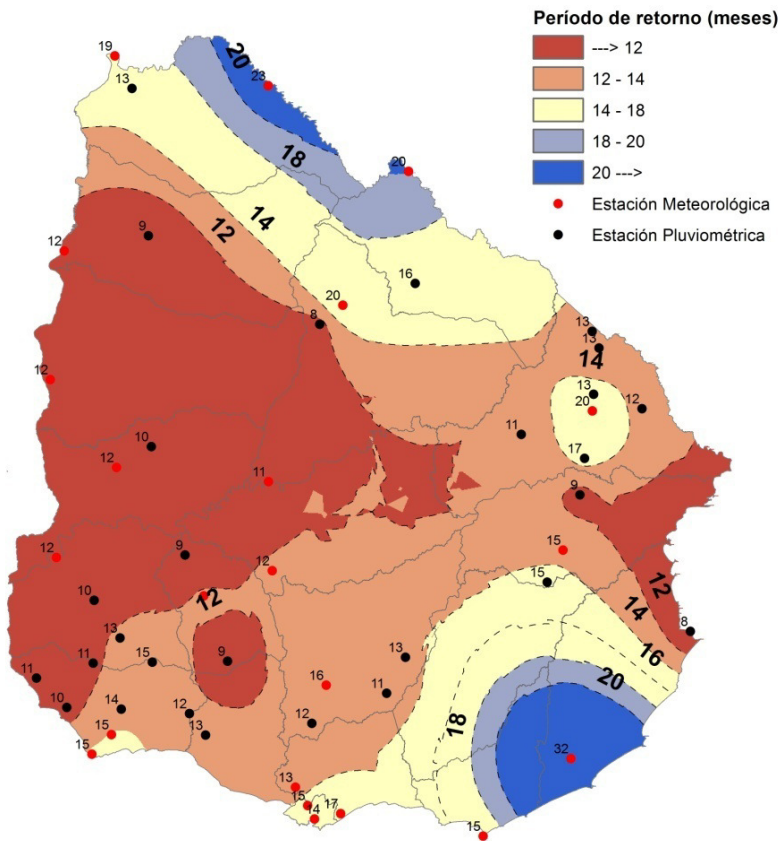


Figura 3-11: Mapa del período de retorno (meses) de rachas secas con una longitud mayor a 30 días.

Por último, con el fin de describir la evolución de los estadísticos a lo largo del año, se calculó su ciclo medio anual. Para su cálculo se aplicó una ventana móvil centrada de ± 30 días y se asignó a cada día del año el valor del muestreo en la ventana.

A modo de ejemplo, a continuación se presentan los resultados obtenidos para cuatro de las estaciones meteorológicas (Artigas, Paysandú, Melo y Prado) que se indican la Figura 3-12. Cabe destacar que, de aquí en adelante, para las valoraciones que impliquen una figura por estación se presentarán solamente los resultados correspondientes a dichas estaciones, las cuales se encuentran bien distribuidas espacialmente.

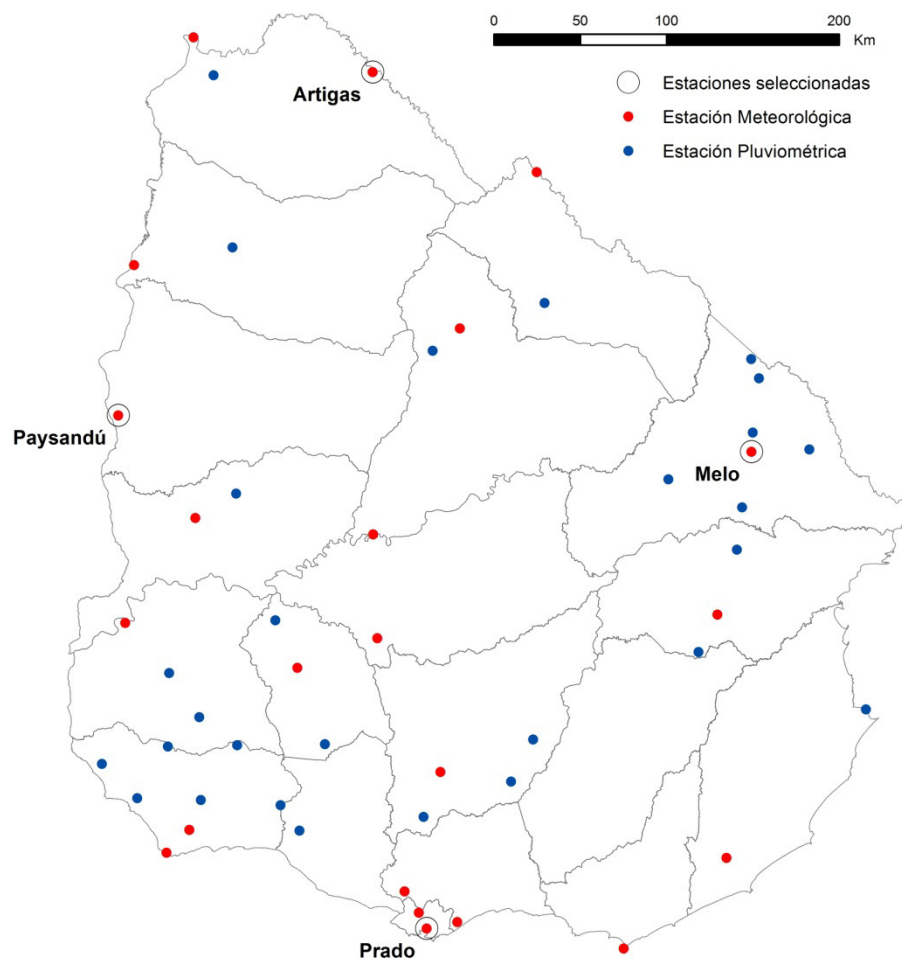


Figura 3-12: Estaciones meteorológicas seleccionadas para presentar los ciclos anuales.

En la Figura 3-13a se presenta el ciclo medio anual de precipitación diaria para las cuatro estaciones seleccionadas. Se observa la existencia de un ciclo anual con una doble estación lluviosa, un máximo principal en otoño y un máximo secundario en primavera, un mínimo principal en invierno y un mínimo secundario en el verano. Características que fueron observadas anteriormente (Terra y Pisciotano, 1994; INIA, 2011), y atribuidas a que el Uruguay se encuentra dentro de la región climática de transición entre el

régimen continental de lluvias estivales, y uno marítimo con máximos en invierno. Dicho ciclo es muy marcado en la región noroeste y norte del país, atenuándose hacia el sureste (Melo y Prado) a medida que nos acercamos al régimen marítimo.

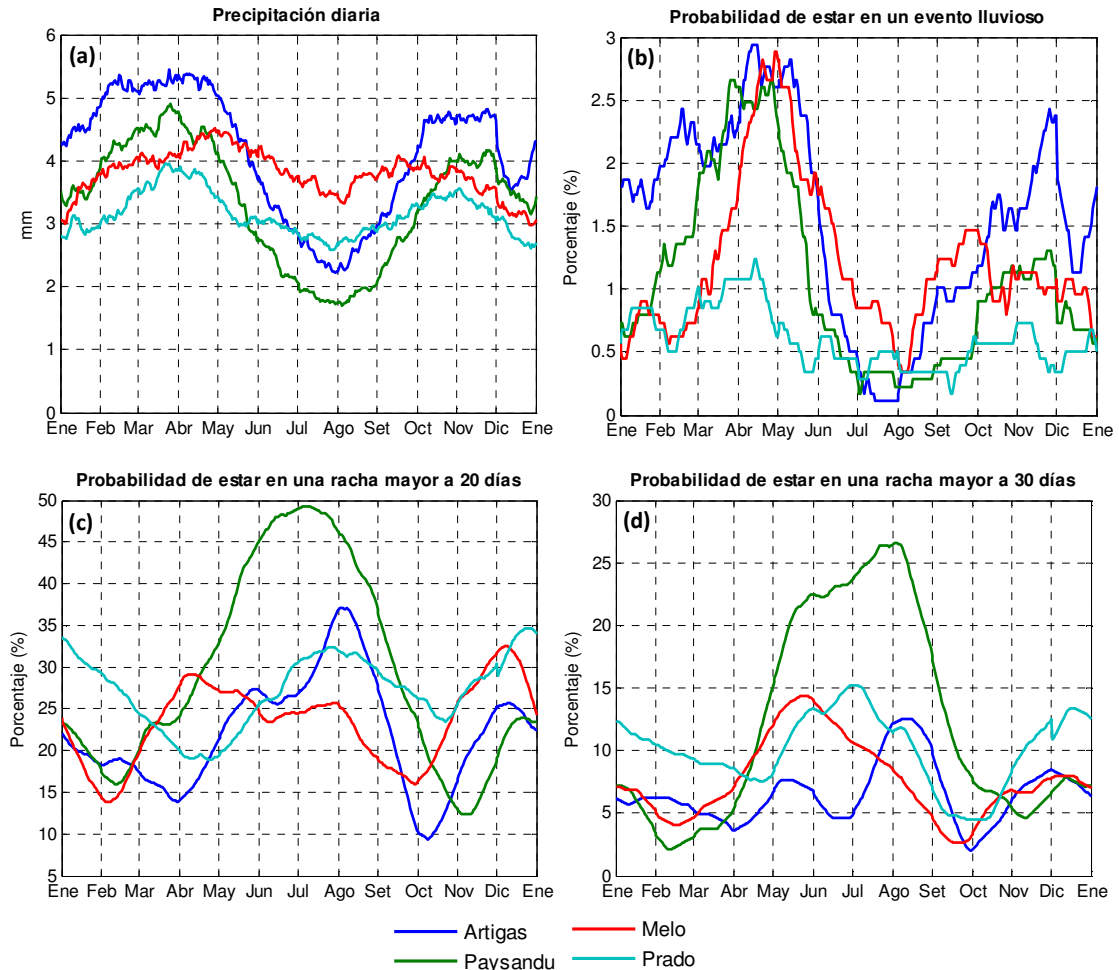


Figura 3-13: Ciclo medio anual de los estadísticos hidro-climáticos para las cuatro estaciones seleccionadas: (a) precipitación diaria, (b) probabilidad de estar en un evento lluvioso, (c) y (d) probabilidad de estar en una racha mayor a 20 y 30 días.

Para representar la evolución en el año de la recurrencia de eventos lluviosos y rachas secas se entendió más apropiado, en lugar de expresarla como período de retorno, expresarla a través de la probabilidad, para cada día del año dado, de estar en un evento (de exceso o déficit hídrico).

En la Figura 3-13b se presenta el ciclo medio anual de la probabilidad, para cada día del año, de estar en un evento lluvioso para las cuatro estaciones seleccionadas. Se observa que, si bien la probabilidad de estar en un evento lluvioso hereda las características ya señaladas para el caso de la precipitación media, tanto en lo que respecta a la variación en el año como a las diferencias entre estaciones, se acentúan las diferencias entre el

sur y norte, donde los eventos de precipitación intensos son mucho más frecuentes.

En las Figura 3-13c y Figura 3-13d se presenta el ciclo medio anual de la probabilidad, para cada día del año, de estar en una racha seca mayor a 20 y 30 días. En las mismas se replican los resultados ya comentados en las Figura 3-10 y 3-11, señalando adicionalmente al invierno como estación del año en donde se verifican las diferencias más importantes entre estaciones.

CAPÍTULO 4

ENTRENAMIENTO Y EVALUACIÓN DE LOS MODELOS IMPLEMENTADOS

4. Entrenamiento y evaluación de los modelos implementados

4.1 ENTRENAMIENTO

En esta sección se presenta el entrenamiento de los modelos desarrollados en las 22 estaciones meteorológicas. Por entrenamiento se refiere a la estimación de los parámetros para cada modelo y punto geográfico.

4.1.1 Markov+Gamma

Modelo anual

En primer lugar se estimaron los parámetros del modelo Markov+Gamma (mediante el método de máxima verosimilitud) asumiendo que los mismos son estacionarios a lo largo del año, es decir, considerando para el ajuste toda la serie de datos disponible sin distinguir entre los meses y/o días del año.

Los parámetros a estimar son los siguientes (Tabla 4-1).

Tabla 4-1: Parámetros del modelo Markov+Gamma.

Parámetro	Descripción
p_{01}	Probabilidad de lluvia dado que no llovió
p_{11}	Probabilidad de lluvia dado que llovió
α	Parámetro de forma de la distribución gamma
β	Parámetro de escala de la distribución gamma

A partir del valor de los parámetros estimados en cada punto, se construyeron mapas para todo el Uruguay mediante el método de interpolación Kriging Ordinario. En el caso del parámetro α sólo se

presentan los valores puntuales, sin interpolar, ya que la interpolación espacial de los mismos produce resultados muy ruidosos.

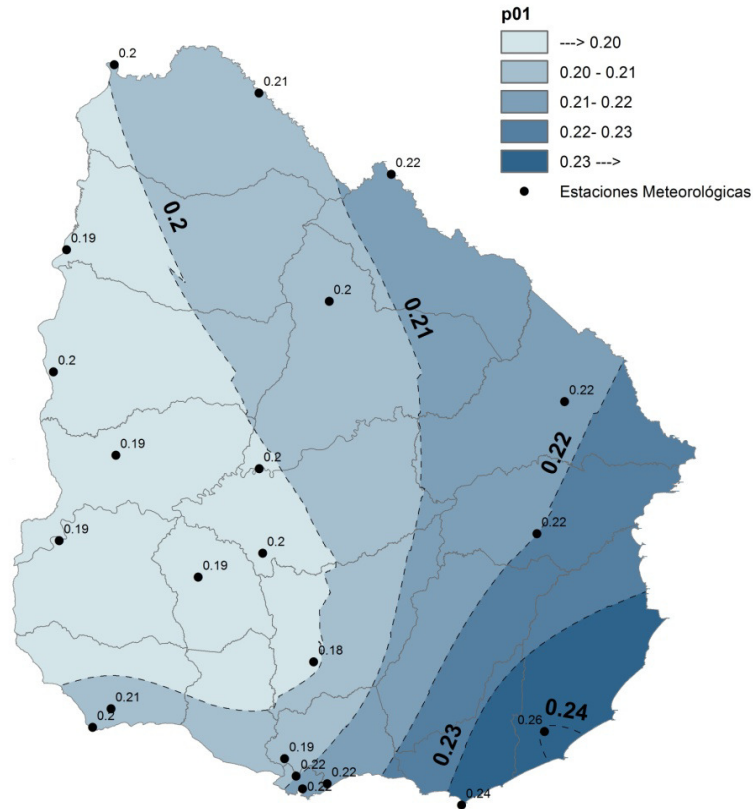


Figura 4-1: Mapa de la probabilidad de lluvia dado que no llovió (p_{01}).

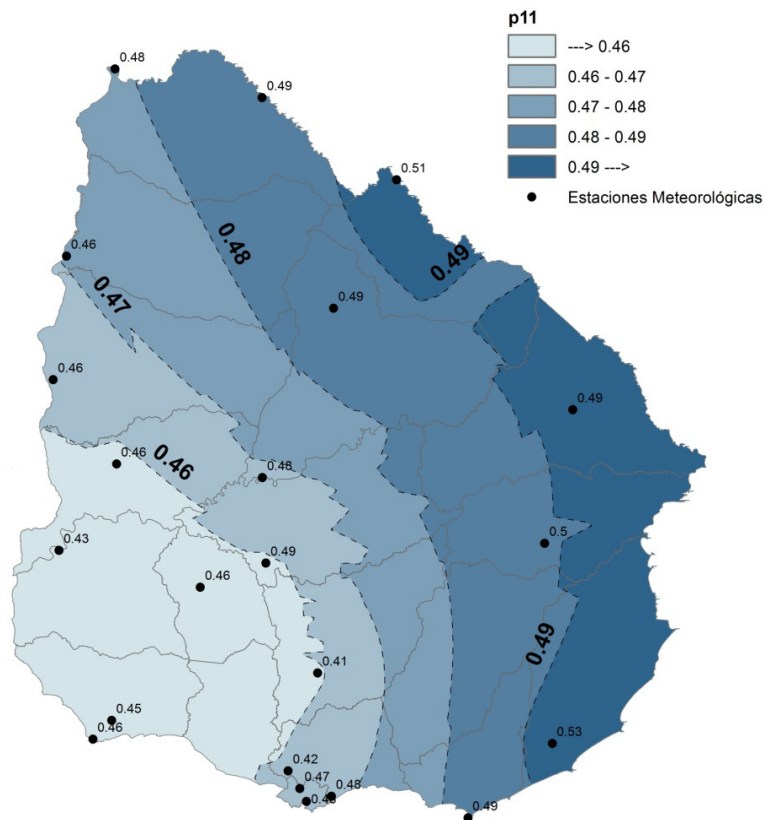


Figura 4-2: Mapa de la probabilidad de lluvia dado que llovió (p_{11}).

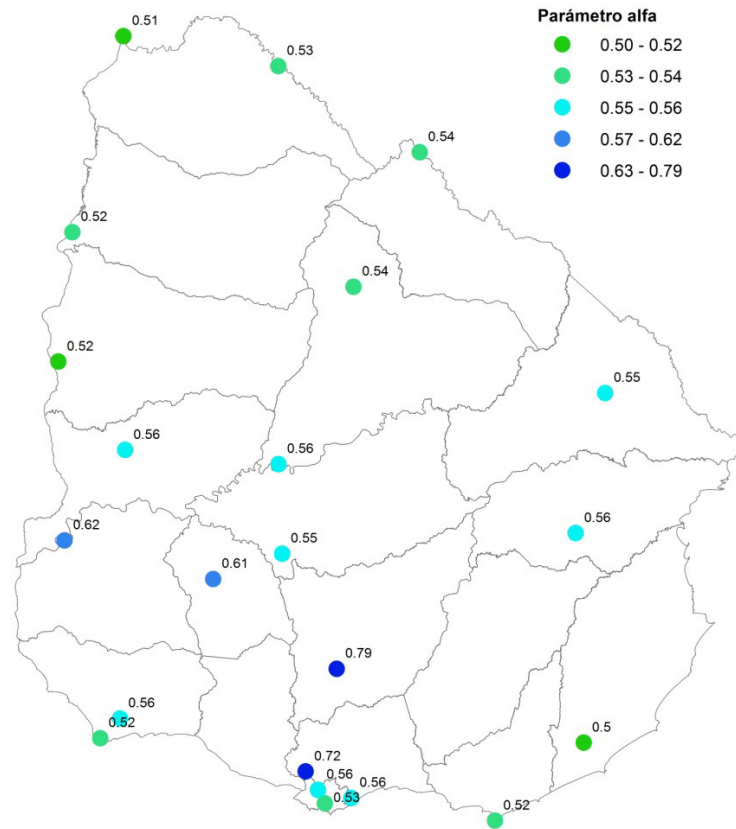


Figura 4-3: Mapa del parámetro α de la distribución gamma.

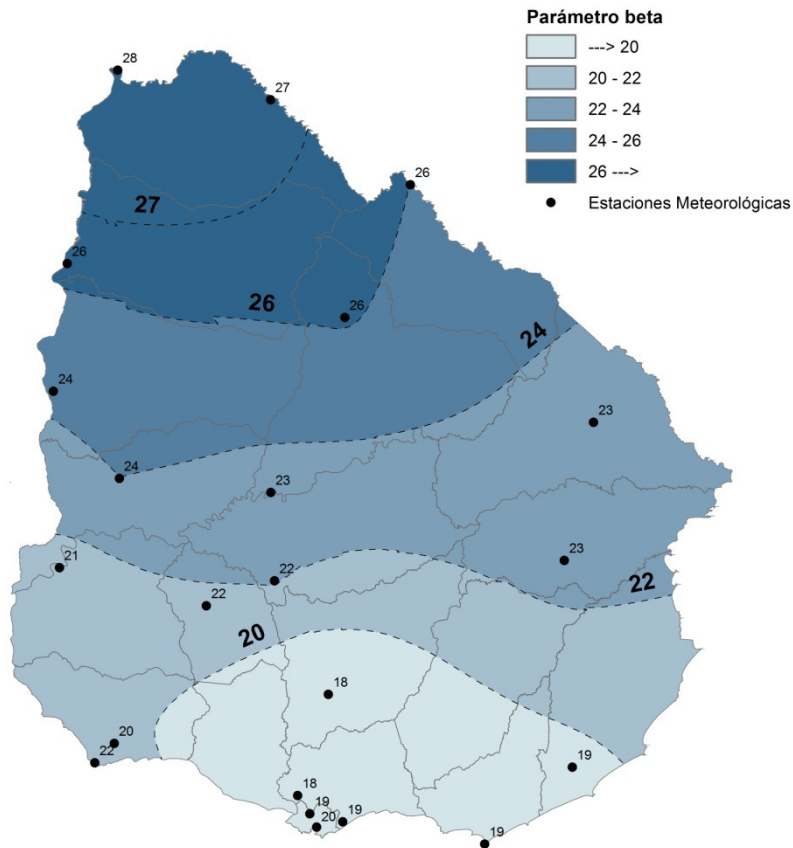


Figura 4-4: Mapa del parámetro β de la distribución gamma.

Se observa que la probabilidad de lluvia dado llovió (p_{11}) es mayor que la probabilidad de lluvia dado que no llovió (p_{01}), lo cual se debe a la naturaleza persistente de la ocurrencia de precipitación diaria en nuestro clima. La p_{01} presenta un gradiente de noroeste a sureste, con un mínimo de 0,18 y un máximo de 0,26; mientras que la p_{11} tiene una tendencia creciente de suroeste a este, con valores de entre 0,41 y 0,53.

El parámetro α varía entre 0,50 y 0,79, concentrándose el 80% de los casos en el intervalo comprendido entre 0,50 y 0,56. Si bien las diferencias relativas son pequeñas y no se distingue una tendencia espacial clara, los mayores valores se ubican en la región suroeste del país.

En relación al parámetro β , se observa un gradiente de sur a norte, coincidente con la tendencia a mayores montos de precipitación observada previamente. Su rango de variación es de 18 a 28 mm.

En la Figura 4-5 se presenta el histograma de intensidad de precipitación diaria para cada una de las cuatro estaciones meteorológicas seleccionadas (Artigas, Paysandú, Melo y Prado), al cual se le superpuso la distribución gamma de mejor ajuste en cada caso.

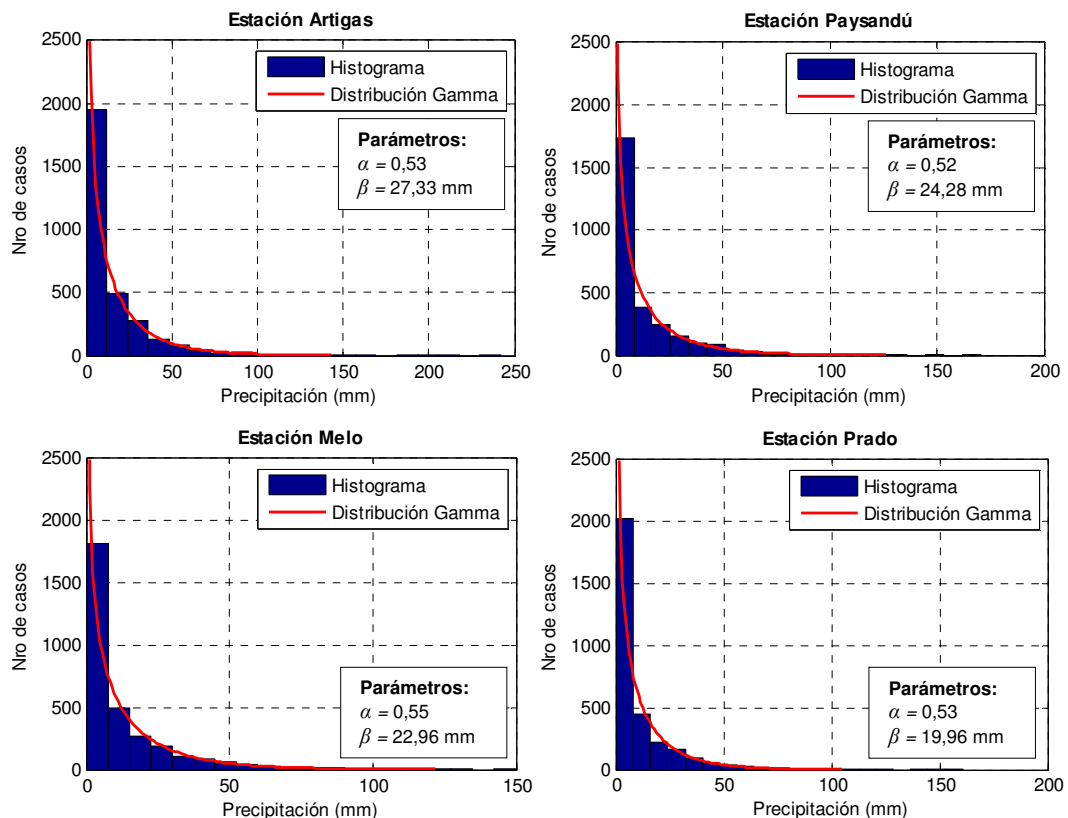


Figura 4-5: Histograma de precipitación diaria y distribución gamma para las cuatro estaciones seleccionadas.

La figura anterior pone de manifiesto la asimetría de la distribución de precipitaciones (distribución asimétrica positiva).

Modelo diario

Luego, con el propósito de incluir en el modelo la variación estacional de la precipitación, se incorporó el ciclo medio anual de cada uno de los parámetros estimados mediante el método de máxima verosimilitud.

Con un registro de N años sólo se dispone de N datos de precipitación para cada día juliano y este número resulta estadísticamente insuficiente aún disponiendo de registros largos. Por lo tanto, se optó por agrupar los datos en períodos móviles centrados de n días y calcular los parámetros para cada período. Para ello se realizó un análisis de sensibilidad a la longitud de la media ventana de muestreo, de forma de obtener una caracterización robusta de los parámetros (a costo de estar representando dicho día con muestreos de otros días que en principio pueden tener un comportamiento distinto). Para cada día del año, se consideró una ventana móvil centrada de $\pm d$ días y se asignó a dicho día el valor del muestreo en la ventana para todos los años (de longitud $2d+1$ días por 29 años). Por simplicidad, no se consideró el día 29 de febrero, ya que sólo se dispone de 7 años bisiestos dentro del período de registro.

En la Figura 4-6 se presentan los ciclos obtenidos para la estación Artigas para una longitud de media ventana de muestreo de 15, 30 y 45 días.

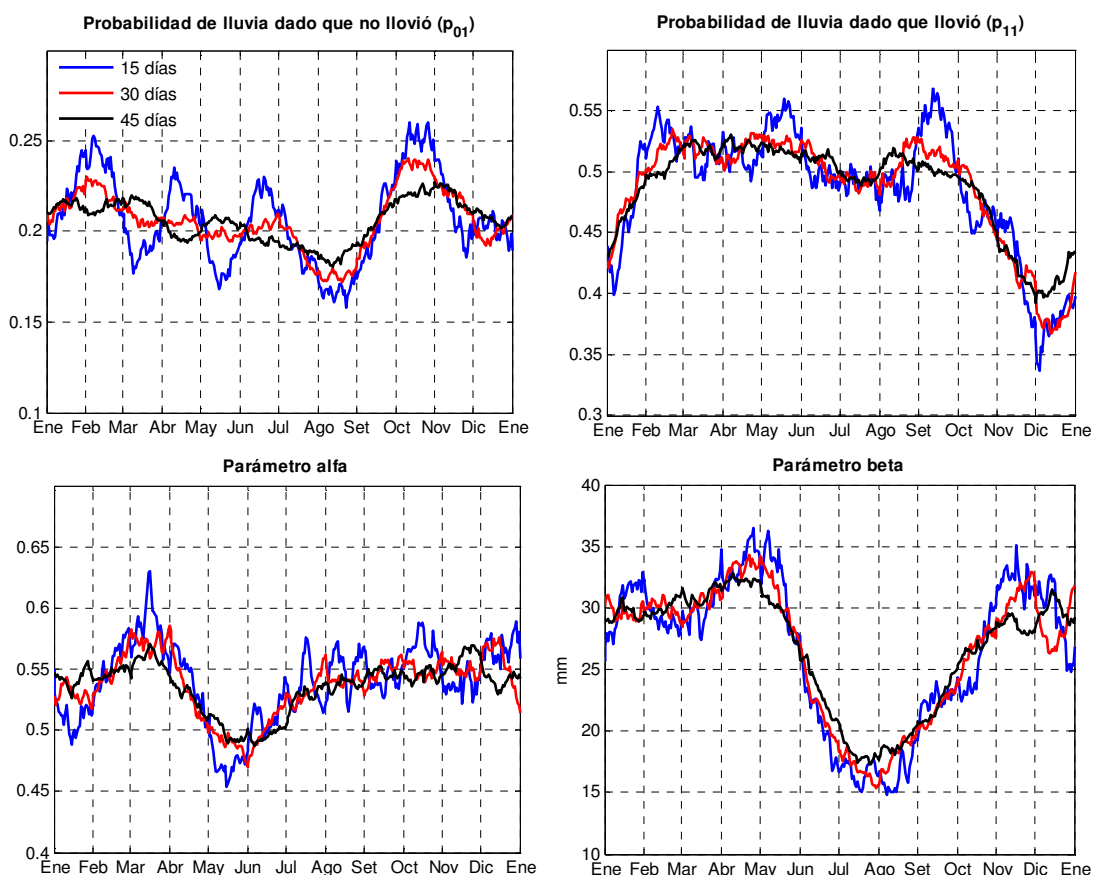


Figura 4-6: Ciclo medio anual de los parámetros del modelo Markov+Gamma para una longitud de media ventana de 15, 30 y 45 días (resultados obtenidos para Artigas).

En dicha figura se puede apreciar la sensibilidad a la longitud de la ventana de muestreo para estos estadísticos. Para el resto de las estaciones se obtuvo un comportamiento análogo.

Se eligió entonces, por suavidad, una longitud de media ventana de muestreo de **30 días**.

Se calculó luego, para cada estación meteorológica, los ciclos medios anuales de los parámetros del modelo Markov+Gamma considerando dicha longitud de media ventana.

A modo de ejemplo, a continuación se presentan los resultados obtenidos para las cuatro estaciones meteorológicas seleccionadas.

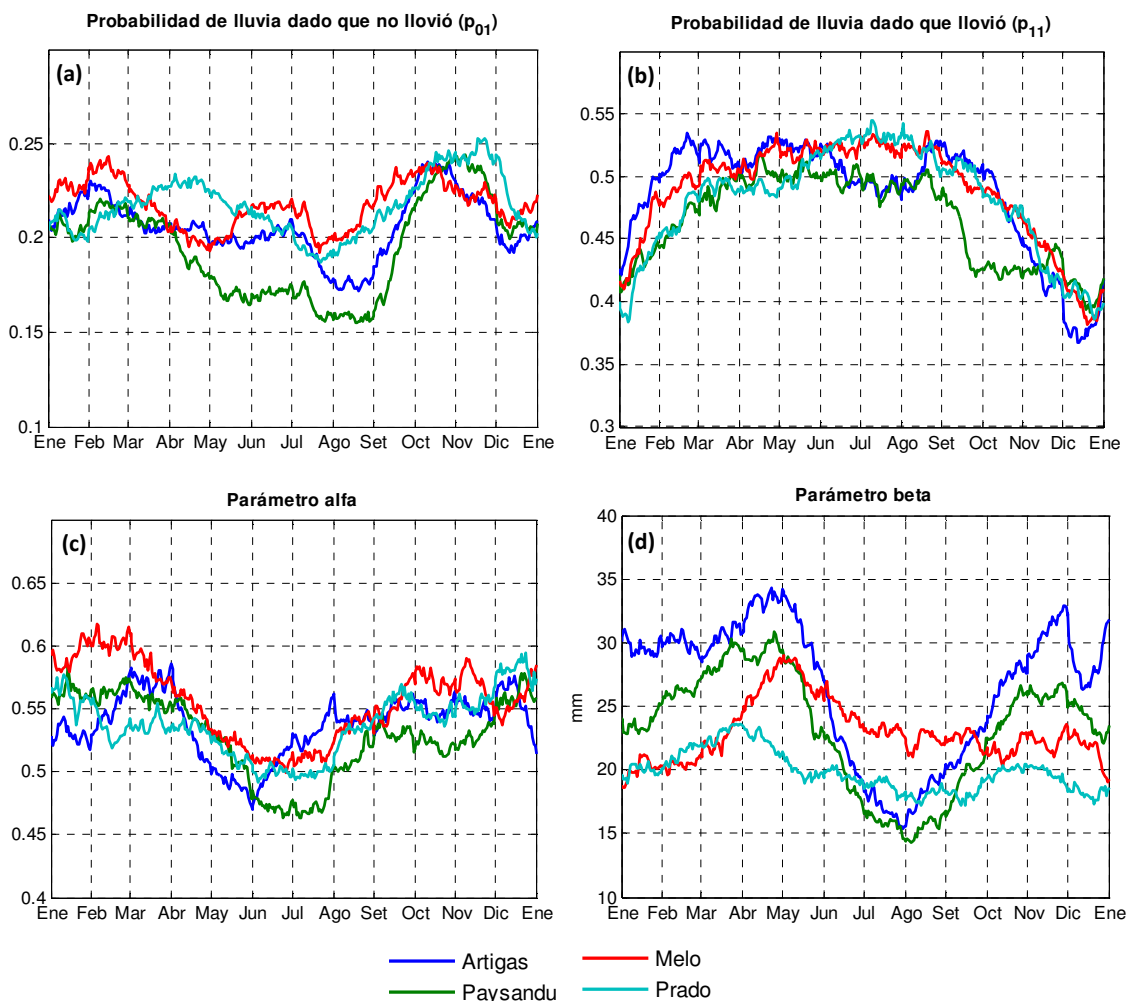


Figura 4-7: Ciclo medio anual de los parámetros del modelo Markov+Gamma.

Nuevamente se observa que p_{11} es mayor a p_{01} (debido a la persistencia de la ocurrencia de precipitación diaria en nuestro clima).

En todos los casos el parámetro α es inferior a 1, confirmando que la distribución de intensidad de precipitación diaria está fuertemente sesgada a la derecha.

Es interesante resaltar la similitud entre la forma del ciclo medio anual de precipitación (Figura 3-13a) y el del parámetro β (Figura 4-7d).

4.1.2 Markov+ExpMixta

El generador Markov+Exp.Mixta fue implementado considerando parámetros variables a lo largo del año, con procedimiento análogo al explicado para el generador Markov+Gamma (Modelo diario).

Los parámetros a estimar en este caso son los siguientes (Tabla 4-2).

Tabla 4-2: Parámetros del modelo Markov+ExpMixta.


Parámetro	Descripción
p_{01}	Probabilidad de lluvia dado que no llovió
p_{11}	Probabilidad de lluvia dado que llovió
α	Parámetro de ponderación
β_1	Parámetro de la distribución exponencial 1
β_2	Parámetro de la distribución exponencial 2

A modo de ejemplo, en la Figura 4-8 se presentan los ciclos medios anuales de los parámetros de la distribución exponencial mixta para las cuatro estaciones meteorológicas seleccionadas (para una longitud de media ventana de muestro de 30 días). No se presentan aquí los ciclos de p_{01} y p_{11} , ya que coinciden con los presentados en la Figura 4-7.

Se observa que en general el parámetro de ponderación (α) varía entre 0,60 y 0,80, siendo por lo tanto más probable muestrear la distribución exponencial de parámetro β_1 que la de parámetro β_2 (cabe recordar que $\beta_1 \geq \beta_2$).

En relación al parámetro β_1 , su ciclo anual es muy similar al del parámetro β de la distribución gamma, aunque levemente atenuado.

El parámetro β_2 presenta un ciclo anual mucho menos marcado, con valores comprendidos entre 0,5 y 2 mm.



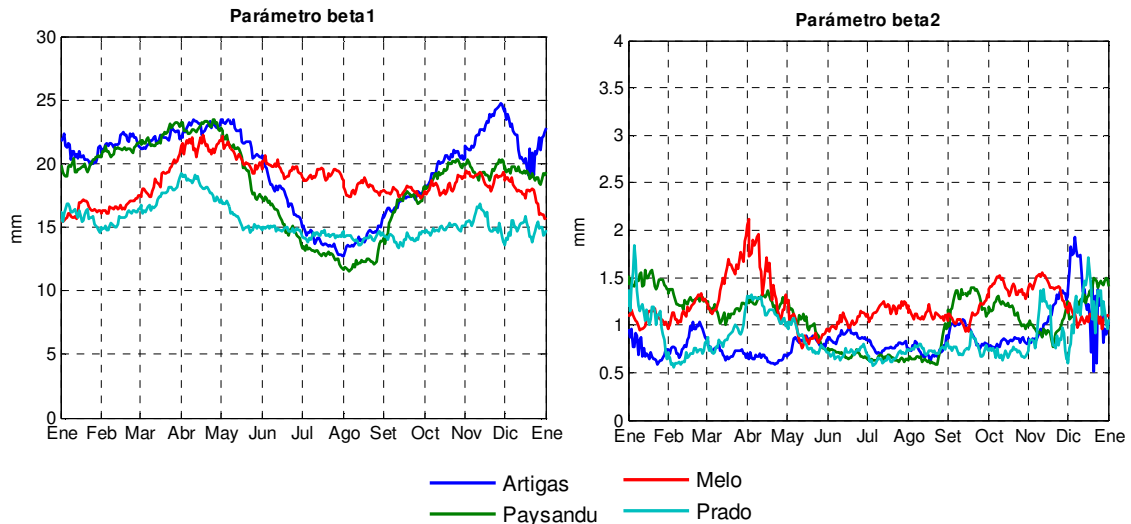


Figura 4-8: Ciclo medio anual de los parámetros del modelo Markov+ExpMixta.

4.2 EVALUACIÓN

Una vez estimados los parámetros de cada generador de tiempo, se procedió a su evaluación comparativa con el propósito de seleccionar el modelo estocástico más adecuado para la simulación de la precipitación diaria en Uruguay.

El análisis se dividió en dos grandes etapas:

- **Modelo anual versus Modelo diario**, empleando el generador de clima Markov+Gamma.
- **Distribución gamma versus Distribución exponencial mixta**, con parámetros variables a lo largo del año.

A continuación se presentan los principales resultados obtenidos.

4.2.1 Modelo anual .vs. Modelo diario

Se partió del generador de clima Markov+Gamma y se realizó una evaluación comparativa entre el modelo anual y el modelo diario.

Para cada modelo y punto geográfico se simularon 100 series de 10.585 días de longitud, equivalentes al largo de las series históricas disponibles (período 1981-2009).

Luego, se evaluó la capacidad del ensemble generado en cada caso para reproducir el ciclo y media anual de determinados estadísticos de las series observadas.

La Figura 4-9 muestra las nubes de puntos para la frecuencia de días de lluvia (%), las probabilidades de que llueva condicionales a que llovió o no llovió el día anterior y la precipitación diaria de las series observadas

versus las series simuladas con el modelo anual y el modelo diario (un punto por estación).

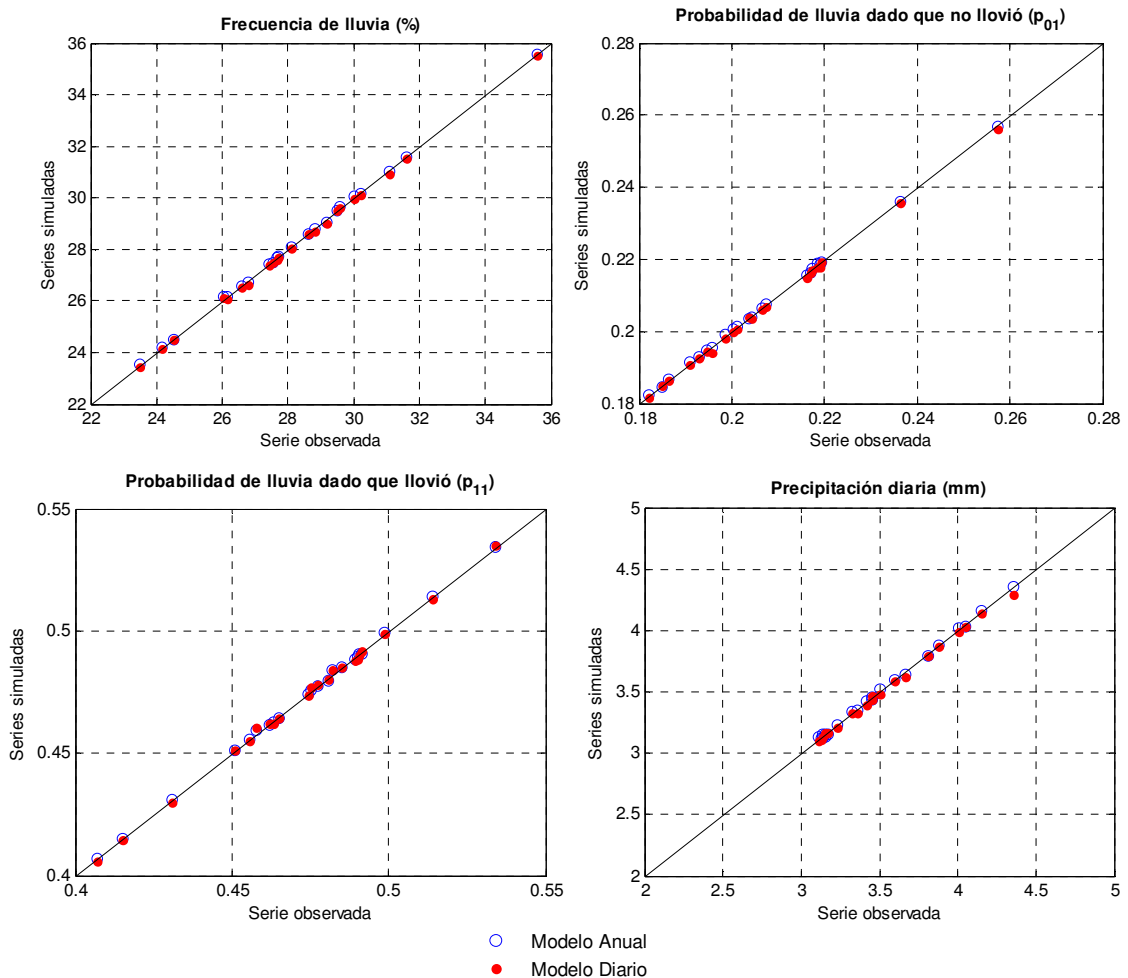


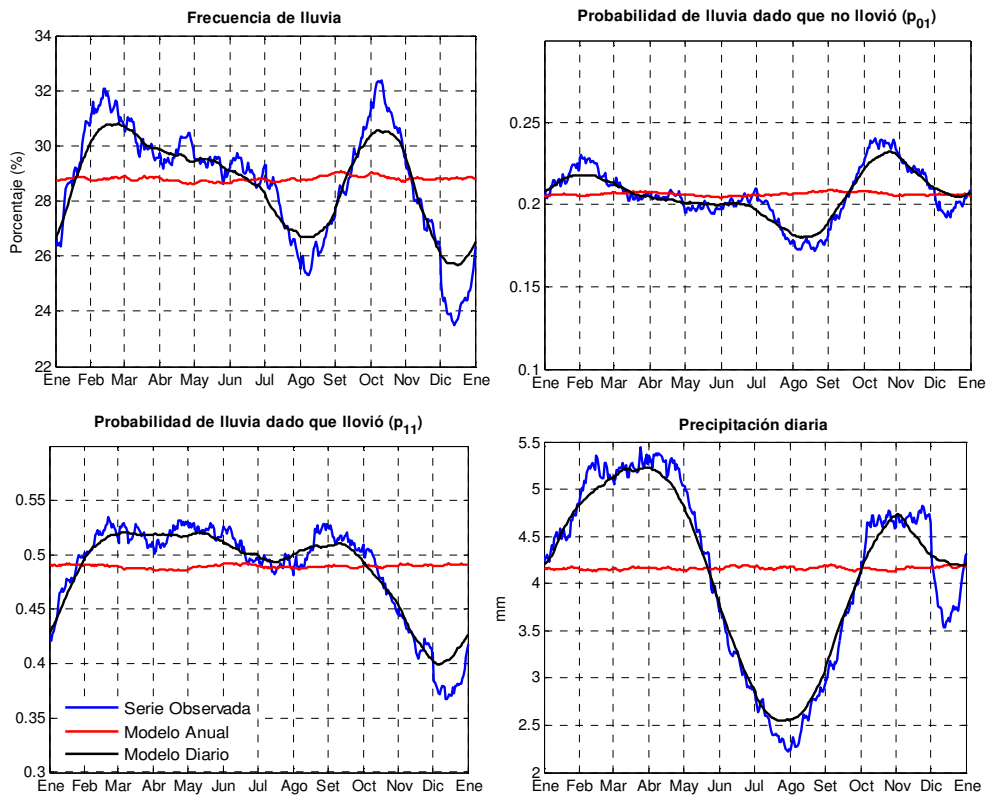
Figura 4-9: Nubes de puntos para la frecuencia de días de lluvia (%), las probabilidades de que llueva condicionales a que llovió o no llovió el día anterior y la precipitación diaria de las series observadas versus las series simuladas con el modelo anual y el modelo diario (un punto por estación).

Se observa que en general las series simuladas reproducen de manera muy satisfactoria los valores medios anuales de los estadísticos seleccionados de las series observadas, sin apreciarse diferencias significativas entre los dos modelos.

Se construyeron luego los ciclos medios anuales de dichos estadísticos a partir de las series observadas y las series simuladas con el modelo anual y el modelo diario, considerando en todos los casos una longitud de media ventana de muestreo de 30 días.

A modo de ejemplo, a continuación se presentan los resultados obtenidos para las cuatro estaciones seleccionadas. Para el resto de las estaciones se obtuvo un comportamiento análogo.

Estación Artigas



Estación Paysandú

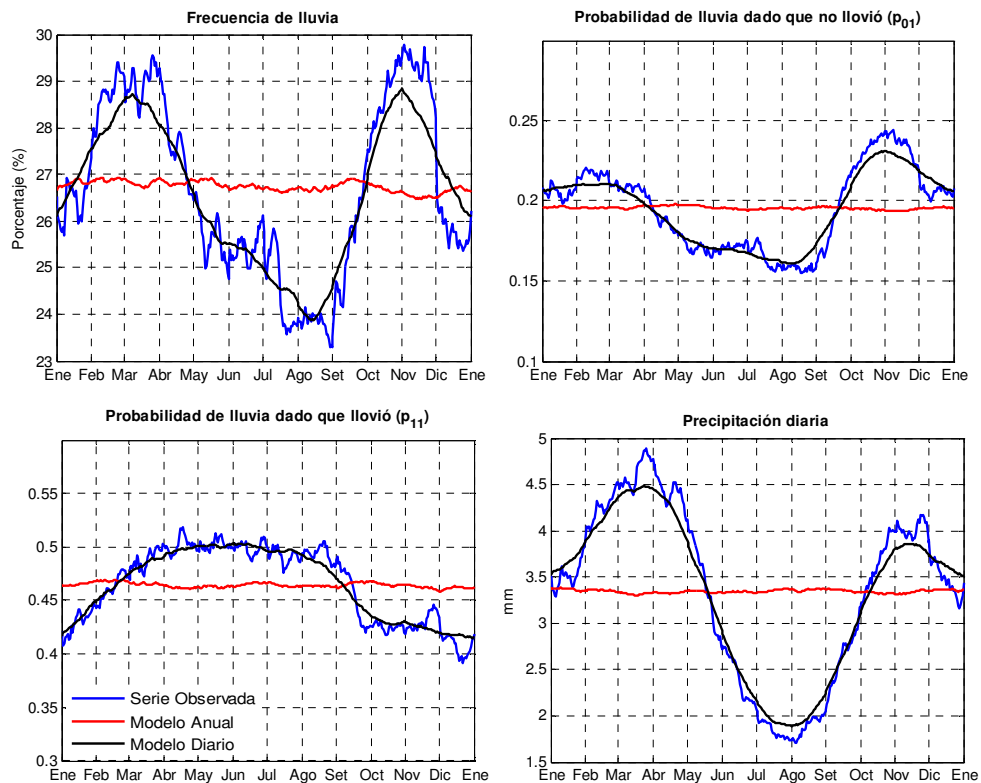
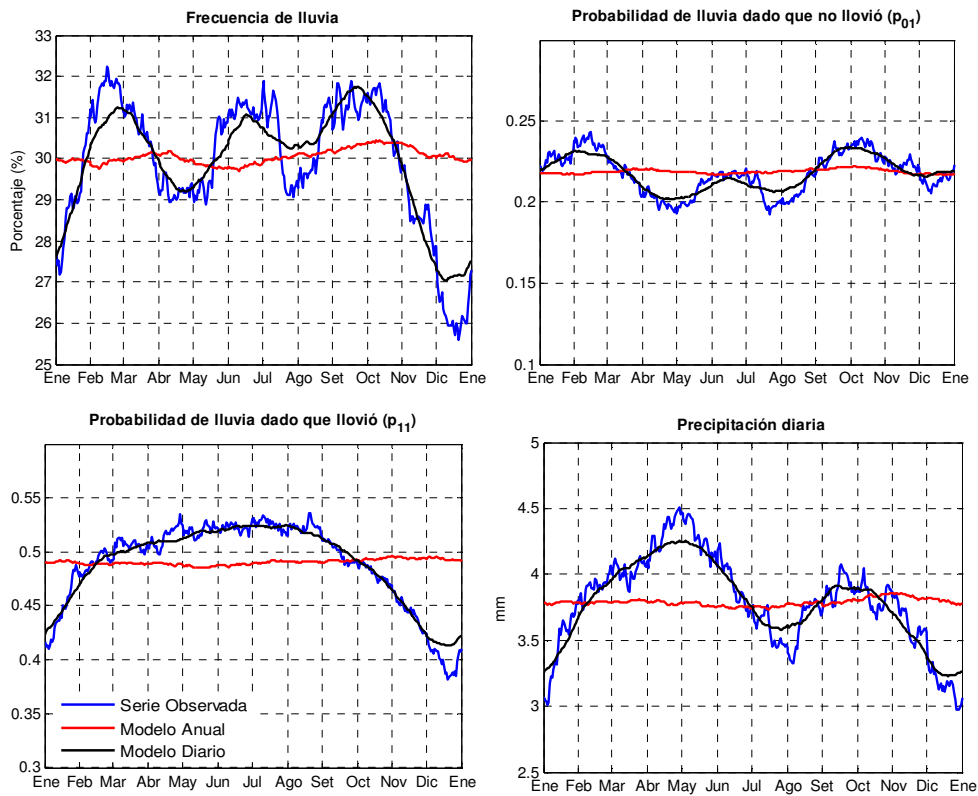


Figura 4-10a: Comparación de los ciclos anuales calculados a partir de la serie observada y las series simuladas con el modelo anual y el modelo diario.

Estación Melo



Estación Prado

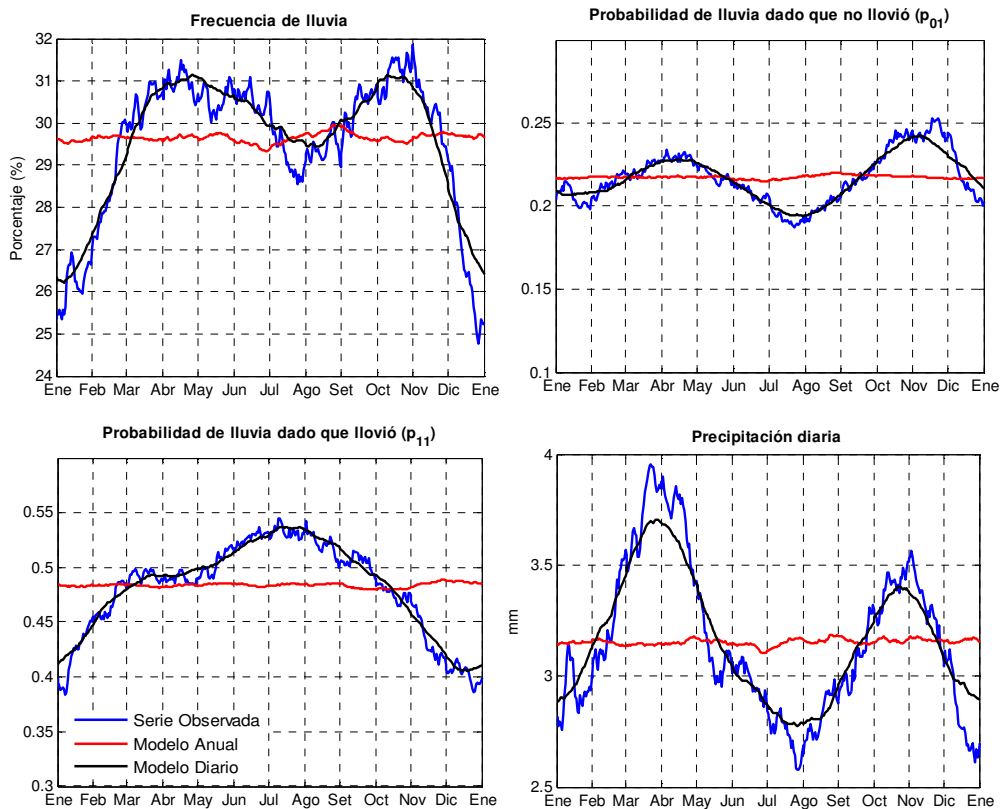


Figura 4-10b: Comparación de los ciclos anuales calculados a partir de la serie observada y las series simuladas con el modelo anual y el modelo diario.

Se observa que las series simuladas reproducen adecuadamente la variación estacional de los estadísticos seleccionados de las series observadas, siendo indiscutible la ventaja de incorporar el ciclo medio anual de los parámetros.

Cabe destacar que, si bien se usó la misma longitud de ventana de muestreo para las series simuladas y las observadas, el ciclo anual de las series sintéticas es más suave debido a que en cada caso se realizaron 100 simulaciones del mismo largo de las series históricas disponibles.

En función de los resultados obtenidos, para los próximos análisis se empleará el **modelo diario**.

4.2.2 Distribución gamma .vs. Distribución exponencial mixta

Se realizó luego una evaluación comparativa de los dos generadores desarrollados, Markov+Gamma y Markov+Exp.Mixta, empleando el modelo diario en ambos casos.

Para cada modelo y punto geográfico se simularon 100 series de 10.585 días de longitud, equivalentes al largo de las series históricas disponibles (período 1981-2009).

Para evaluar la capacidad del ensemble generado en cada caso, se consideraron estadísticos enfocados tanto en los días de lluvia como en los montos de precipitación, a partir de los cuales se realizaron diversos análisis apuntando a la reproducción del ciclo y media anual, así como a la variabilidad interanual y a la distribución de extremos.

Cabe destacar que, si bien los generadores de tiempo son herramientas probadas y de larga tradición, no siempre son capaces de reproducir todos los estadísticos de una serie. Por lo que al momento de utilizar otros estadísticos de las series simuladas, distintos a los aquí considerados, es necesario verificar la capacidad del generador de tiempo de reproducirlos. En particular, cuanto más sensible es el estadístico a eventos extremos muy esporádicos, más difícil es entrenar los modelos para que dicho estadístico sea reproducido adecuadamente.

Distribución de totales diarios, mensuales, trimestrales y anuales

Se construyeron los diagramas de caja de totales diarios, mensuales, trimestrales y anuales de precipitación para las series observadas y las series simuladas con ambos generadores.

En la Figura 4-11 se presentan los resultados obtenidos para las cuatro estaciones meteorológicas seleccionadas. Se incluyen los percentiles 25, 50, 75 (cajas) y 10 y 90 (bigotes).

Se observa que a nivel diario las series simuladas reproducen de manera muy satisfactoria la distribución observada. En todos los casos la distribución exponencial mixta presenta mayor intervalo intercuartil que la distribución gamma y que las series observadas.

A nivel mensual no se distinguen diferencias apreciables entre los dos modelos, presentando ambos muy leves sesgos positivos en los valores centrales (mediana) y menor intervalo entre deciles extremos que las series observadas (excepto para la estación Prado).

A nivel trimestral y anual, las precipitaciones observadas presentan mayor dispersión que las simuladas, lo cual es síntoma de que estas últimas no capturan adecuadamente la variabilidad en escalas multimensual e interanual. En general no se aprecian diferencias significativas entre los dos generadores.

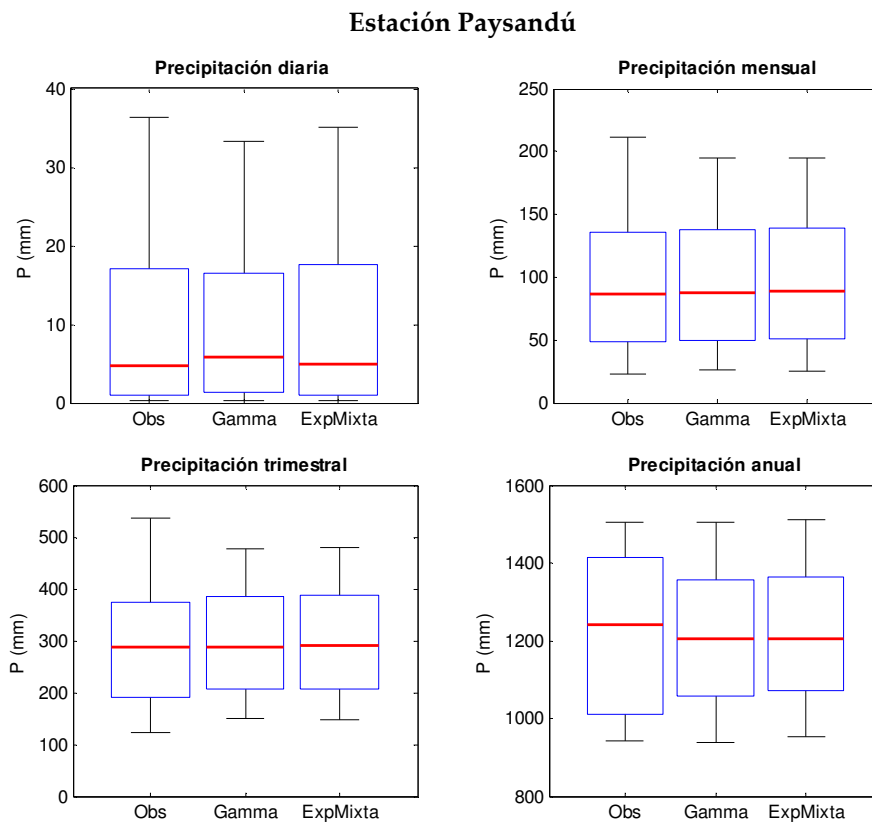
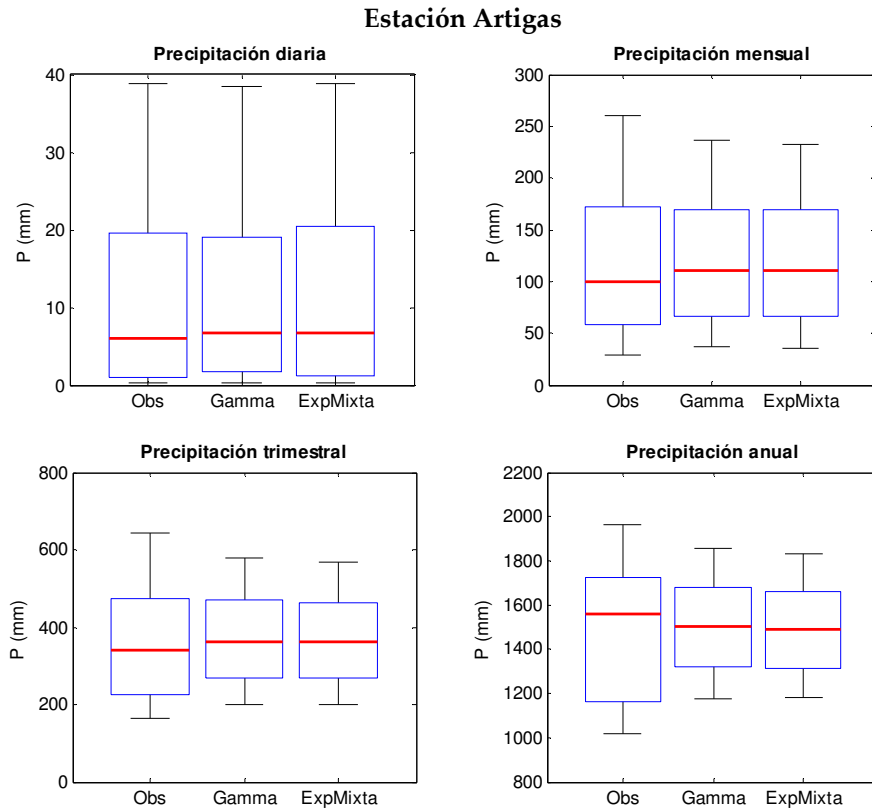
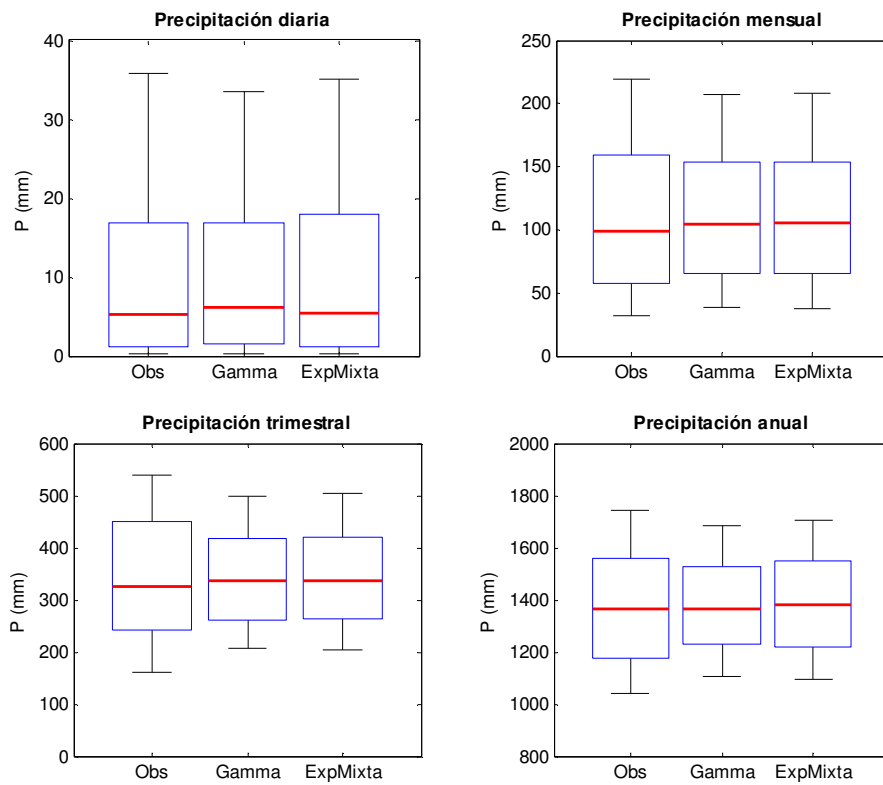


Figura 4-11a: Diagramas de caja de totales diarios, mensuales, trimestrales y anuales de precipitación para la serie observada y las series simuladas. Se incluyen los percentiles 25, 50, 75 (cajas) y 10 y 90 (bigotes).

Estación Melo



Estación Prado

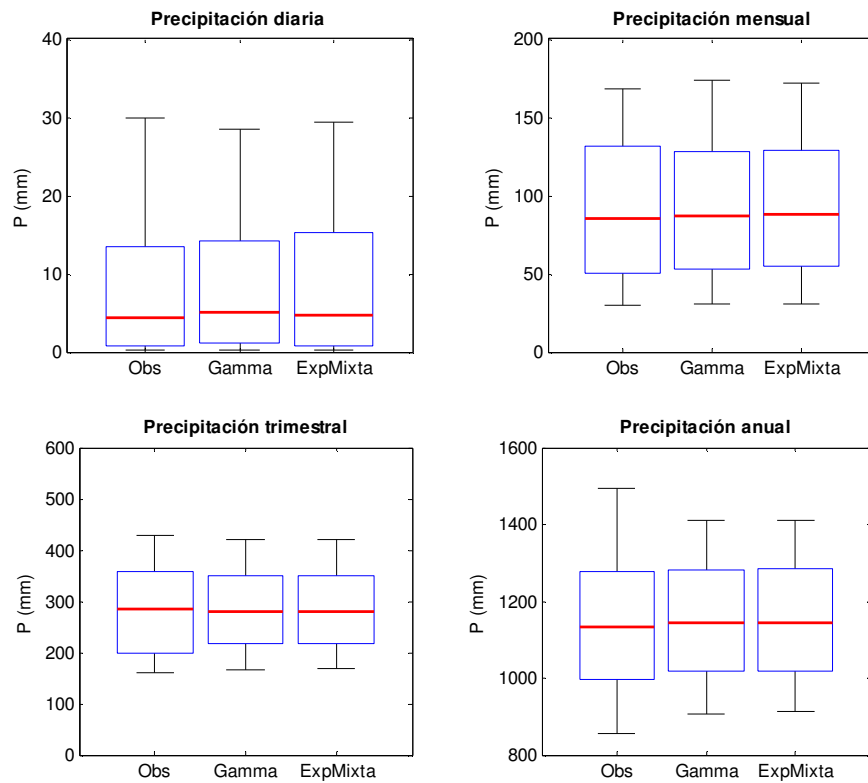


Figura 4-11b: Diagramas de caja de totales diarios, mensuales, trimestrales y anuales de precipitación para la serie observada y las series simuladas. Se incluyen los percentiles 25, 50, 75 (cajas) y 10 y 90 (bigotes).

Reproducción del ciclo medio anual

Luego, se construyó el ciclo medio anual de la precipitación diaria, la probabilidad -para cada día del año- de estar en un evento lluvioso y de estar en una racha seca mayor a 20 y 30 días a partir de la serie observada y las series simuladas (considerando una longitud de media ventana de muestro de 30 días).

Se recuerda que, en el presente estudio, una *racha seca* se define como el conjunto de días consecutivos en que el acumulado no supera 10 mm; y un *evento lluvioso* se configura cuando el acumulado de 3 días es mayor o igual a 100 mm.

A continuación se presentan los resultados obtenidos para las cuatro estaciones seleccionadas (Figura 4-12).

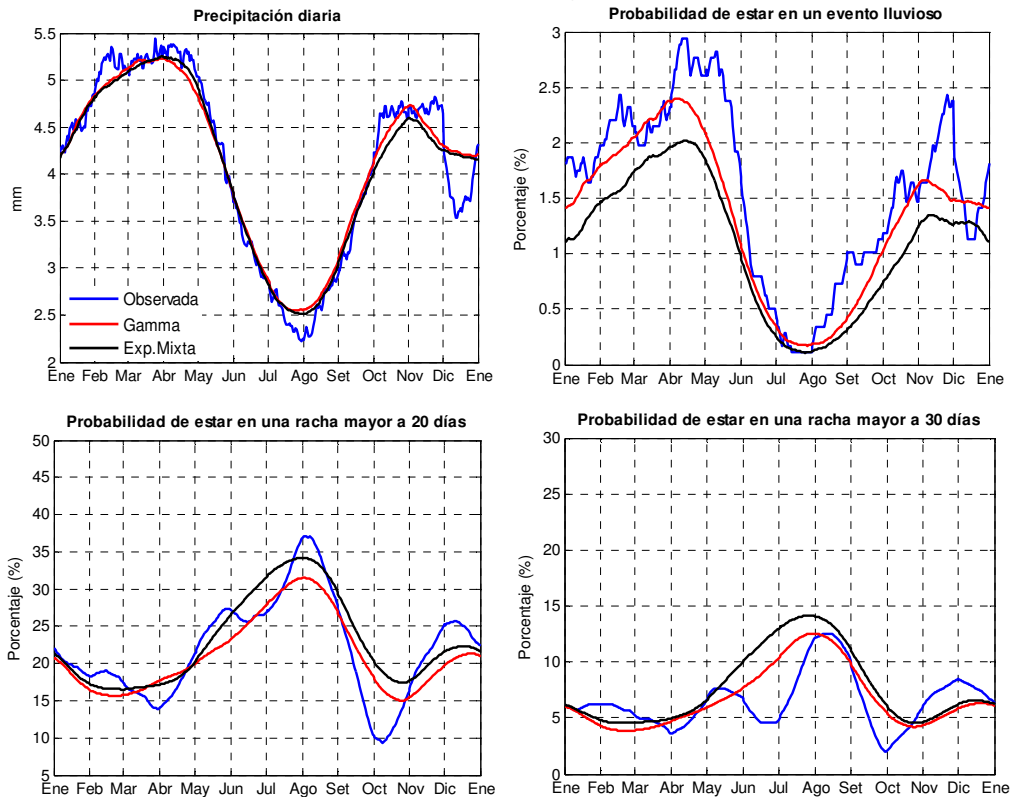
Se observa que en general las series simuladas reproducen de manera satisfactoria el ciclo medio anual de los estadísticos seleccionados de las series observadas.

En relación al ciclo anual de precipitación diaria, no se distinguen diferencias significativas entre los dos modelos; presentando ambos un muy buen desempeño.

Para los eventos lluviosos, se observa que ambos modelos presentan un sesgo hacia menores valores de probabilidad, teniendo el generador Markov+Gamma un desempeño marginalmente superior que el Markov+Exp.Mixta.

En cuanto a la recurrencia de rachas secas, nuevamente se observa en ambos modelos un leve sesgo a menores probabilidades, haciéndose más notorio a medida que nos movemos hacia el sur del país. Si bien este estadístico depende fundamentalmente de las probabilidades de que llueva condicionales a que llovió o no llovió el día anterior y, en menor medida, de los montos de precipitación, se observa que el generador Markov+Exp.Mixta presenta un desempeño marginalmente superior que el Markov+Gamma.

Estación Artigas



Estación Paysandú

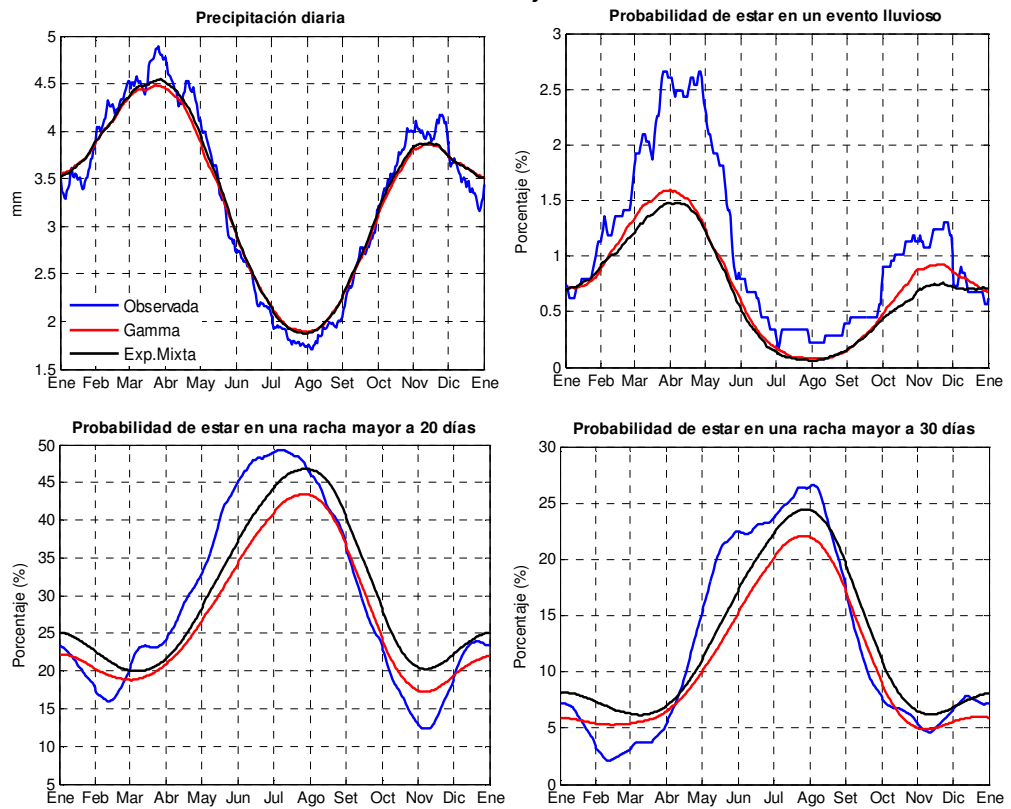
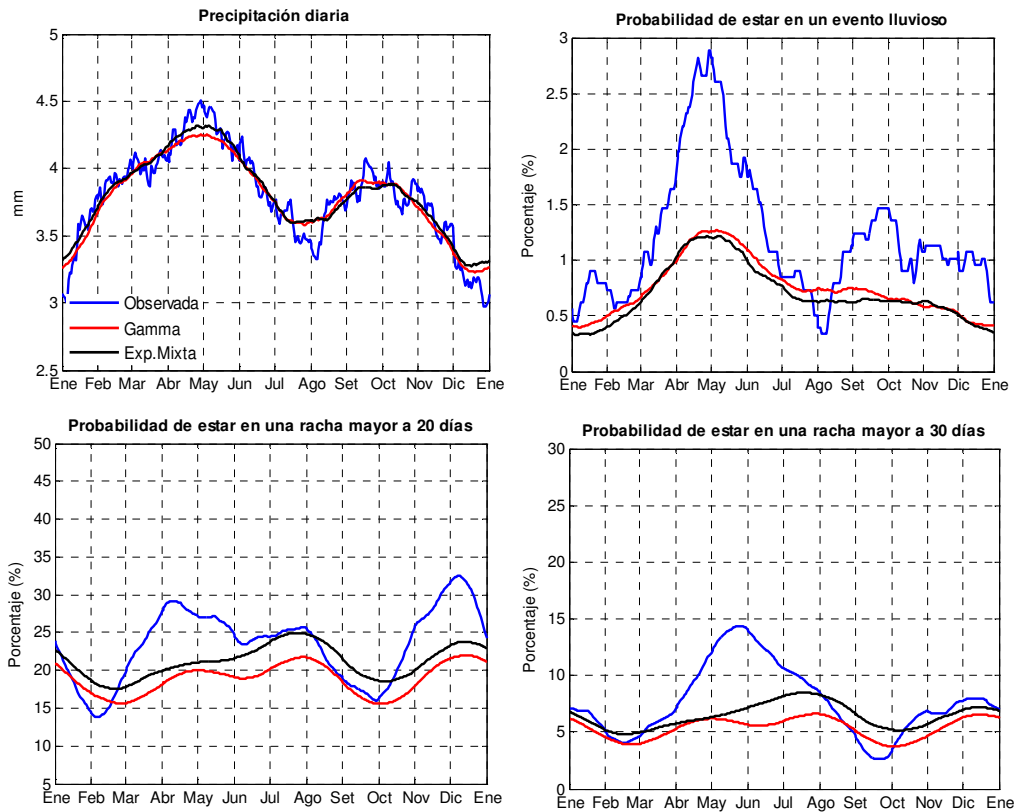


Figura 4-12a: Ciclo medio anual de precipitación diaria, probabilidad de estar en un evento lluvioso y probabilidad de estar en una racha mayor a 20 y 30 días para la serie observada y las series simuladas.

Estación Melo



Estación Prado

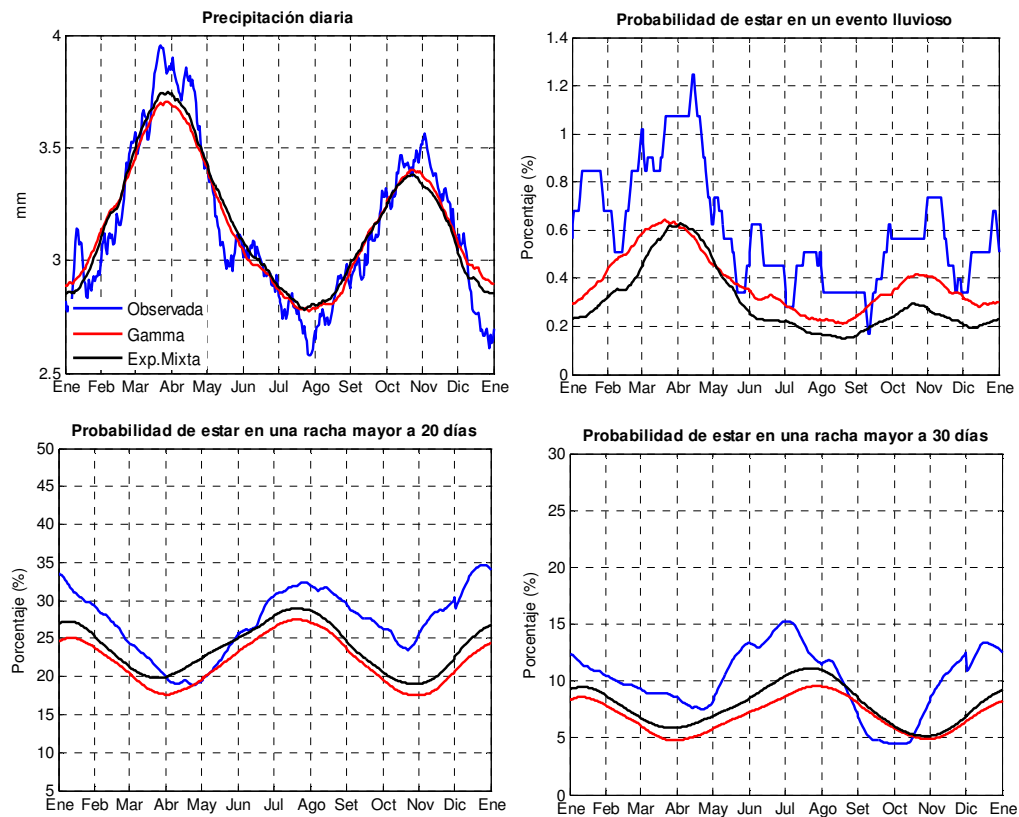


Figura 4-12b: Ciclo medio anual de precipitación diaria, probabilidad de estar en un evento lluvioso y probabilidad de estar en una racha mayor a 20 y 30 días para la serie observada y las series simuladas.

Variabilidad interanual

La reproducción a partir de generadores estocásticos, o al menos una buena aproximación, de la variabilidad interanual observada es una característica deseable en muchas aplicaciones. Sin embargo, en general se ha demostrado que el tipo de generadores de tiempo aquí desarrollados subestima las variaciones de baja frecuencia (mayor a varios años). Este fenómeno se denomina comúnmente “sobredispersión” (Wilks, 1999a).

Con el objetivo de evaluar la capacidad de los modelos para reproducir dicha variabilidad, es posible descomponer la variabilidad interanual de la precipitación mensual en dos componentes que dependen de aspectos particulares de la ocurrencia e intensidad de la precipitación diaria.

Sea $S(T)$ la suma de la precipitación diaria de T días consecutivos, es decir, por ejemplo el acumulado mensual (para $T=30$). La varianza $Var[S(T)]$ refleja la variación entre realización y realización en los acumulados de estos T -días, o equivalentemente la varianza interanual. Esta varianza se puede expresar como (Katz y Parlange, 1998; Wilks, 1999a):

$$Var[S(T)] = E[N(T)] \times \sigma^2 + Var[N(T)] \times \mu^2$$

donde $N(T)$ es el número de días lluviosos durante el período de T -días, $E[]$ es el operador esperanza, $Var[]$ es el operador varianza, y μ y σ^2 son la media y la varianza de la cantidad de precipitación de los días lluviosos en el período de T -días.

En el caso de los generadores implementados, las cantidades $E[N(T)]$ y $Var[N(T)]$ dependen de los modelos de ocurrencia de precipitación, mientras que las cantidades μ y σ^2 (en las cuales se centrará este análisis) dependen de los modelos de intensidad de precipitación.

Dado que anteriormente se demostró que la media μ de la cantidad de precipitación de los días lluviosos está representada de forma muy satisfactoria por cada uno de los modelos de intensidad de precipitación diaria considerados, el análisis se enfocará en la capacidad de los modelos en reproducir la varianza de la cantidad de precipitación.

La Figura 4-13 muestra la relación entre la desviación estándar de la cantidad de precipitación de los días lluviosos (mm/día de lluvia) en el período de T -días (para $T=30, 90$ y 365 días) de las series observadas y las series simuladas con la distribución gamma y la distribución exponencial mixta (un punto por cada período de T -días para cada estación). También se indica en cada caso el respectivo coeficiente de sobredispersión, expresado como porcentaje y promediado para todos los períodos de T -días y todas las estaciones, según:

$$Overdispersion\ Coef = \left(\frac{Varianza\ Obs}{Varianza\ Sim} - 1 \right) \times 100\%$$

Cuanto menor sea este coeficiente (más próximo a cero), mejor será el desempeño del modelo.

STD $[S(T)/N(T)]$

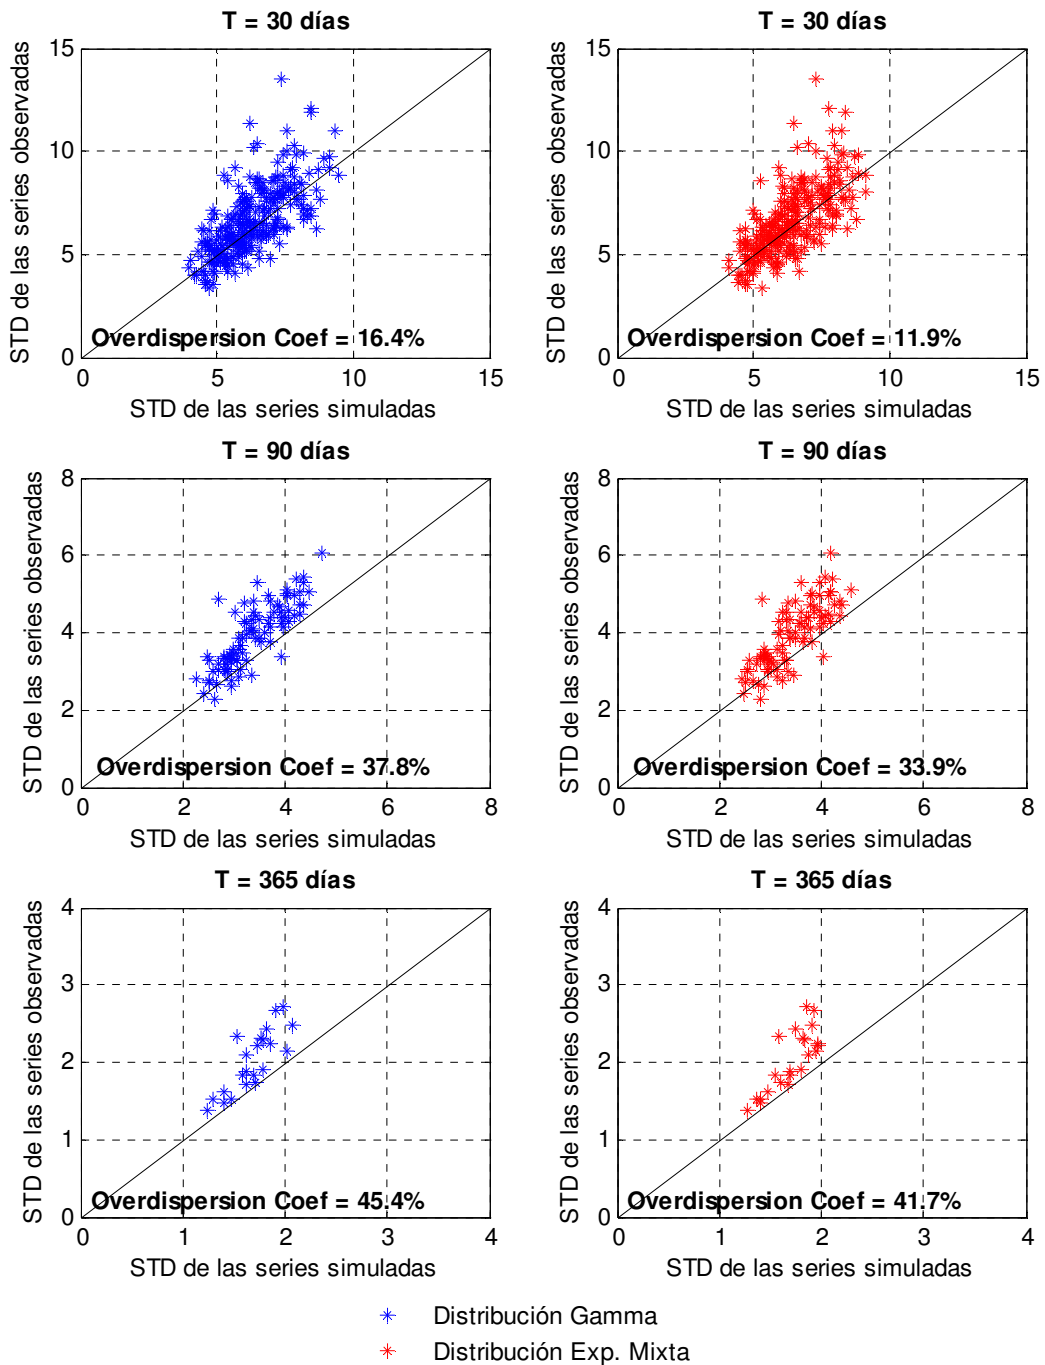


Figura 4-13: Desviación estándar de la cantidad de precipitación de los días lluviosos (mm/día de lluvia) en el período de T-días (para T= 30, 90 y 365 días) de las series observadas y simuladas con la distribución gamma y la distribución exponencial mixta.

Análogamente, en la Figura 4-14 se presenta la relación entre la desviación estándar del acumulado de precipitación (mm) en el período de T-días

(para $T= 30, 90$ y 365 días) de las series observadas y las series simuladas, junto con su respectivo coeficiente de sobredispersión.

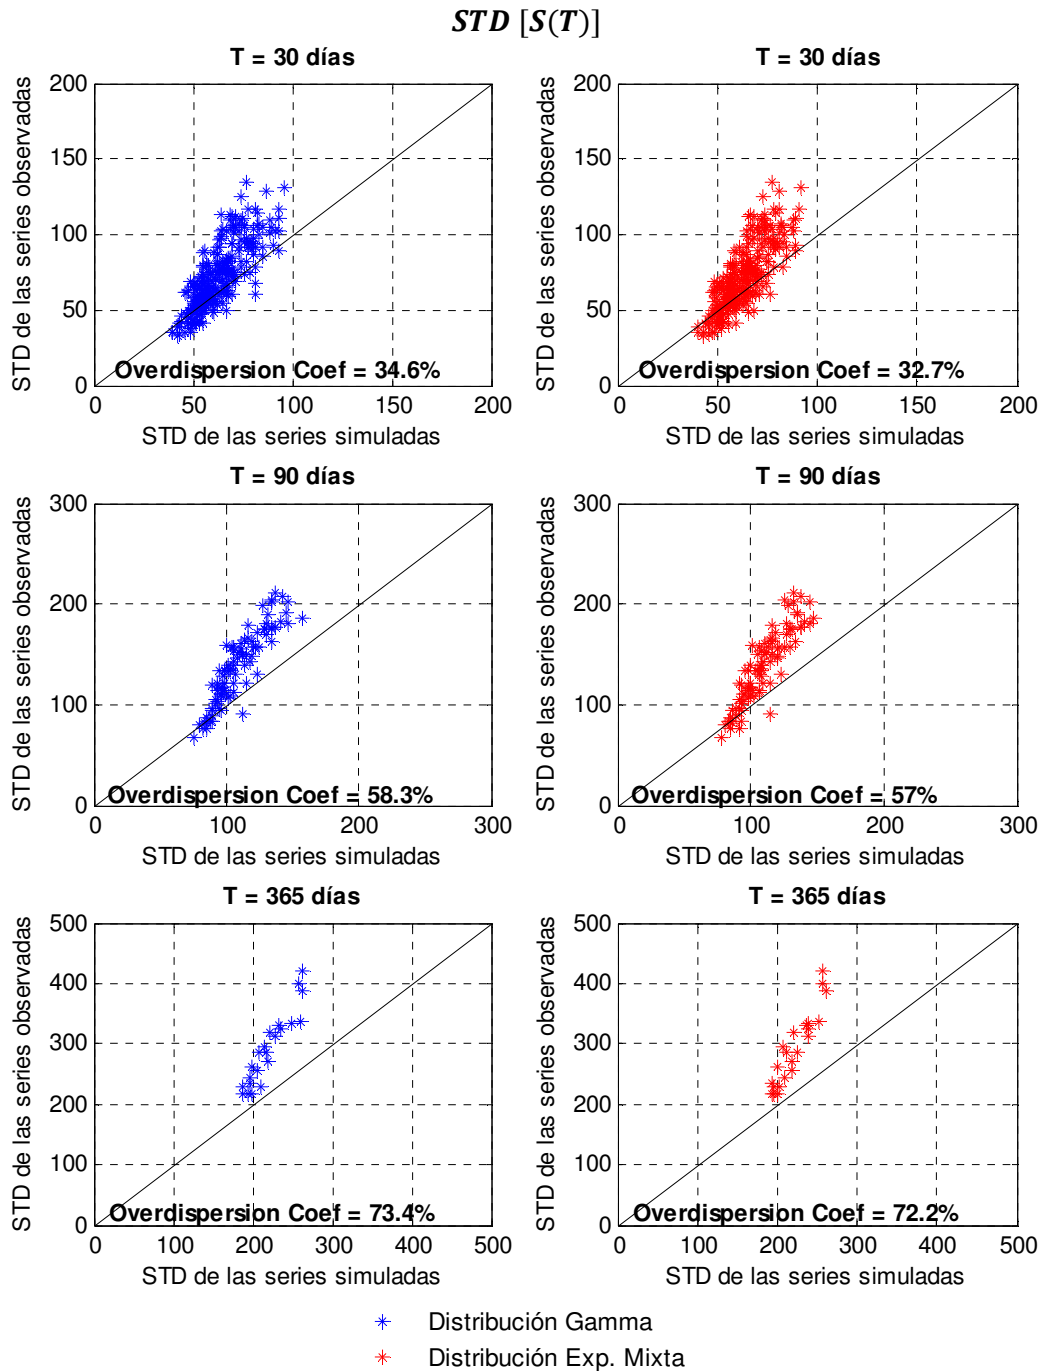


Figura 4-14: Desviación estándar del acumulado de precipitación (mm) en el período de T-días (para $T= 30, 90$ y 365 días) de las series observadas y simuladas con la distribución gamma y la distribución exponencial mixta.

De ambas figuras se desprende que la distribución gamma produce una sobredispersión mayor que la distribución exponencial mixta, con mayores valores del coeficiente de sobredispersión en todos los casos (cuanto mayor es la sobredispersión, mayor es la varianza de las series

observadas respecto de la de las simulaciones). A medida que aumenta la longitud del período de T-días, aumenta considerablemente la sobredispersión, lo cual es síntoma de que los modelos no capturan adecuadamente la variabilidad en escalas multimensual e interanual.

Distribución de rachas extremas

A continuación se explora la capacidad de los modelos para reproducir los valores extremos observados de longitudes de rachas secas.

Para hacer la comparación entre los valores máximos observados y los simulados es necesario estimar la probabilidad acumulada asociada a cada máximo observado. Denotando el valor máximo de n observaciones como $x_{(n)}$, una forma de estimar la correspondiente probabilidad acumulada es (Wilks, 1999a):

$$Pr\{X \leq x_{(n)}\} = \frac{n - 1/3}{n + 1/3} \quad [4-1]$$

Por ejemplo, a la mayor de $n=100$ observaciones se le asignaría una probabilidad acumulada estimada de $99,667/100,333= 0,9934$.

En este caso, dado que se trabajó con las rachas secas máximas anuales, resulta $n= 29$ y $Pr= 0,9773$.

En la Figura 4-15 se comparan los valores máximos observados y los máximos simulados (asociados a dicha Pr) para las 22 estaciones meteorológicas. Cada punto representa la longitud (en cantidad de días) de la racha seca más larga para cada estación. También se indica en cada caso el respectivo error medio (en cantidad de días), promediado para todas las estaciones.




Figura 4-15: Comparación entre la máxima longitud (días) de rachas secas de las series observadas y simuladas con el modelo Markov+Gamma y el modelo Markov+Exp.Mixta (un punto por estación).

Se observa que ambos modelos son capaces de simular razonablemente bien este estadístico, subestimando las rachas con longitudes mayores a 60 días en el caso del modelo Markov+Gamma y a 65 días en el caso de Markov+Exp.Mixta.

El modelo Markov+Exp.Mixta presenta menor error medio (en valor absoluto) que el modelo Markov+Gamma (-7,5 días versus -9,9 días).

Máxima precipitación diaria

Se estudió también la capacidad de los modelos para reproducir los valores extremos observados de precipitación diaria.

Con procedimiento análogo al presentado para la caracterización de rachas secas extremas, se calculó la probabilidad acumulada asociada a cada máximo observado según la ecuación [4-1], de forma de contemplar el problema del mayor muestreo en las simulaciones que en las observaciones.

En la Figura 4-16 se comparan los valores máximos observados y los máximos simulados para las 22 estaciones meteorológicas (cada punto representa la precipitación máxima diaria para cada estación). También se indica en cada caso el respectivo error medio (en mm), promediado para todas las estaciones.




Figura 4-16: Comparación entre la precipitación máxima diaria (mm) de las series observadas y simuladas con la distribución gamma y la distribución exponencial mixta (un punto por estación).

Se observa que los modelos son capaces de simular razonablemente bien este estadístico, subestimando los montos mayores a 200 mm en el caso del modelo Markov+Gamma y a 170 mm en el caso de Markov+Exp.Mixta.

La distribución gamma presenta menor error medio (en valor absoluto) que la distribución exponencial mixta (-28 mm versus -38 mm).

Criterio BIC

Finalmente, se evaluó la bondad del ajuste de cada distribución de intensidad de precipitación diaria según el criterio BIC:

$$BIC(m) = -2L(\theta) + m \cdot \ln(n)$$

donde m es el número de parámetros, n es la longitud de la serie de datos, y $L(\theta)$ es la función de log-verosimilitud evaluada en θ , siendo θ los valores de los parámetros que maximizan la función de verosimilitud.

Para cada estación y para cada día del año, se calculó el estadístico BIC para la distribución gamma y la exponencial mixta (Figura 4-17) y se contó la frecuencia en que cada distribución es seleccionada (Figura 4-18); el mejor modelo es aquel que presenta el menor valor.




Figura 4-17: Comparación del valor del estadístico BIC obtenido para la distribución gamma y la exponencial mixta (un punto para cada día y estación).




Figura 4-18: Frecuencia en que cada distribución es seleccionada según el BIC.

Se observa que el valor del estadístico BIC para cada distribución es muy similar (puntos próximos a la recta $x=y$ en la Figura 4-17). Sin embargo, para todas las estaciones analizadas, la distribución gamma fue seleccionada al menos el 70% de los días.

Conclusiones

De los resultados obtenidos para Uruguay, se desprende que si bien el generador Markov+Exp.Mixta tiene un desempeño marginalmente superior que el Markov+Gamma (sobre todo en lo que refiere a la variabilidad interanual), no se justifica el uso de un modelo menos parsimonioso (con un parámetro más).

Esta conclusión resulta interesante ya que, según numerosos trabajos anteriores (Woolhiser y Roldan (1982), Wilks (1998), Wilks (1999a), Wilks y Wilby (1999) para Estados Unidos y Detzel (2011) para Brasil), la distribución exponencial mixta tiene un desempeño sustancialmente superior que la distribución gamma.

En la Figura 4-19 se presenta una comparación entre los resultados obtenidos por Wilks (1999a), en base a 30 estaciones localizadas en Estados Unidos en el período 1948-1997, y los obtenidos en el presente trabajo para la precipitación máxima diaria de las series observadas y simuladas con la distribución gamma y la distribución exponencial mixta (los ejes están en escala logarítmica).

Se observa que la dispersión de las nubes de puntos obtenidas en ambos casos es similar. Sin embargo, es muy notoria la diferencia en cuanto al rango de variación de los valores de precipitación máxima diaria, siendo mucho más acotado para el caso de Uruguay. Esto se debe a la gran extensión superficial considerada en el estudio de Wilks (Estados Unidos), con una gran diversidad climática, en contraposición a la extensión de Uruguay, sin sistemas orográficos importantes, que contribuye a que las variaciones espaciales sean pequeñas.

Lo anterior confirma que la bondad del ajuste proporcionado por los distintos modelos es variable, dependiendo principalmente de la diversidad de regímenes climáticos en la región donde el modelo va a ser implementado.

En este sentido, dadas las características del clima y la extensión de Uruguay, se llegó a que no se justifica el uso de distribuciones mixtas para simular la intensidad de precipitación diaria.

Por lo tanto, para los próximos análisis se empleará el **modelo Markov+Gamma**.

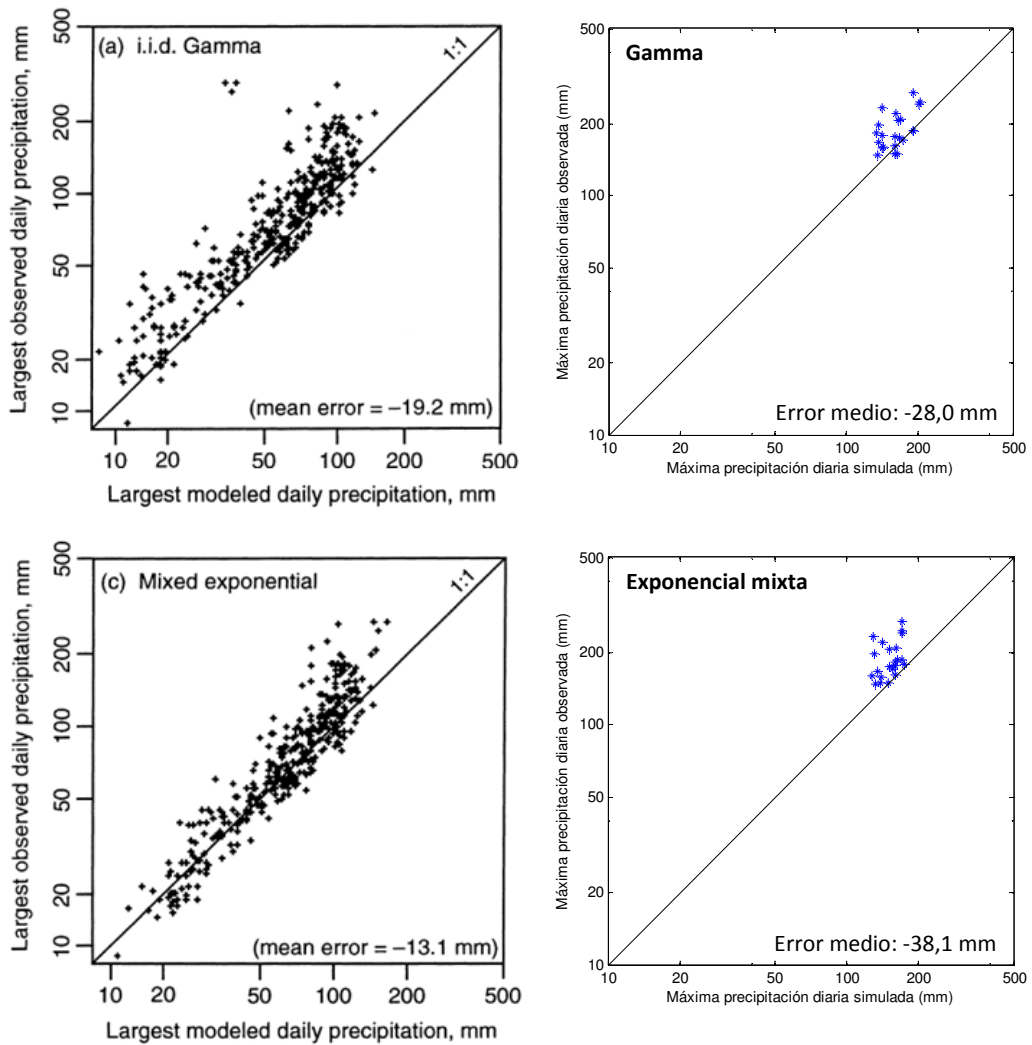


Figura 4-19: Comparación entre los resultados obtenidos por Wilks (1999a) y los obtenidos en el presente trabajo para la precipitación máxima diaria (mm) de las series observadas y simuladas con la distribución gamma y la distribución exponencial mixta (los ejes están en escala logarítmica).

Por último, a modo de verificación, se calculó el ciclo medio anual de los parámetros del modelo Markov+Gamma a partir de las series simuladas considerando una longitud de media ventana de 30 días.

En la Figura 4-20 se presentan los resultados obtenidos para la estación Artigas. Para el resto de las estaciones se obtuvo un comportamiento análogo.

Se observa que se recupera satisfactoriamente el ciclo medio anual de los parámetros del modelo que generó las propias series sintéticas.

Estación Artigas




Figura 4-20: Ciclo medio anual de los parámetros del modelo Markov+Gamma a partir de la serie observada y las series simuladas para la estación Artigas.

CAPÍTULO 5

INCORPORACIÓN DE SESGOS CLIMÁTICOS

5. Incorporación de sesgos climáticos

En este capítulo se presenta la incorporación de sesgos climáticos al generador de tiempo seleccionado, buscando que dicha herramienta sea útil para la aplicación en sistemas expuestos a riesgo climático.

5.1 INTRODUCCIÓN

En ocasiones existen circunstancias climáticas que permiten prever sesgos en la distribución esperada del clima (precipitación, temperatura) en una región y estación dada. Tal es el caso del impacto del fenómeno ENOS (Aceituno, 1992) sobre el clima en diversas regiones del planeta (Ropelewski y Halpert, 1987 y 1989). El sudeste de América del Sur, y en particular Uruguay, es una de dichas regiones cuyo clima se ve condicionado por ENOS para ciertas estaciones del año (Pisciottano et al., 1994; Díaz et al., 1998; Cazes-Boezio et al., 2003).

El fenómeno ENOS es una interacción cuasi-periódica entre la atmósfera y el Océano Pacífico tropical. Los eventos extremos de ENOS se definen cuando existen anomalías significativas de temperatura superficial del mar (TSM) en el Pacífico tropical ecuatorial: ante anomalías positivas se denominan eventos El Niño (fase cálida extrema) y ante anomalías negativas La Niña (fase fría extrema).

Cuando ocurre un evento El Niño, se registran en Uruguay anomalías positivas en la precipitación entre octubre y diciembre del año del Niño y, aunque de manera más débil, entre marzo y julio del año siguiente. Por el contrario, cuando ocurre un evento La Niña, tiende a disminuir la precipitación en la región del Uruguay; los períodos son muy parecidos

pero no necesariamente idénticos. Existen también variaciones regionales en el impacto.

Existen distintos índices basados en la TSM según la región del Pacífico ecuatorial que se considere (Trenberth, 1997). En este trabajo se utilizó el índice *Niño 3.4* (N3.4), que se calcula como el promedio de la TSM en el área definida por 120° O-170° O y 5° N-5° S (ver Figura 5-1).




Figura 5-1: Región del Pacífico ecuatorial donde se calcula el índice N3.4.

(http://www.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ninoareas_c.jpg)

Este índice se encuentra disponible en forma mensual desde enero de 1950 hasta el presente, a través de <http://www.cpc.ncep.noaa.gov/data/indices>. En la Figura 5-2 se presenta la serie temporal de las anomalías mensuales del índice N3.4, la cual constituye la forma usual de presentarlo. Las anomalías se obtienen como desviaciones respecto del ciclo anual.




Figura 5-2: Serie temporal de anomalías mensuales del índice N3.4, desde enero de 1950 a diciembre de 2009.

Una ventaja del uso de este índice (N3.4) es que existen pronósticos de la evolución del mismo con hasta un año de antelación de numerosos centros de todo el mundo. Los mismos están fácilmente disponibles y cuentan con valoraciones de la habilidad de predicción en el pasado (<http://iri.columbia.edu/our-expertise/climate/forecasts/enso/current/>).

5.2 CARACTERIZACIÓN DE ENOS EN URUGUAY

A continuación se presenta una descripción de los sesgos inducidos por la señal de ENOS en la precipitación en Uruguay en función del momento del año. Al igual que en los capítulos anteriores, se consideraron estadísticos enfocados tanto en los días de lluvia como en los montos de precipitación.

Para ello se dispone de series largas de precipitación diaria (desde 1950) para algunas estaciones (Artigas, Paysandú, Mercedes, La Estanzuela, Melo y Rocha), que son necesarias para tener una cobertura temporal mayor y -en particular- un mayor muestreo condicionado a ENOS.

Como variable de condicionamiento se emplearon las anomalías del índice N3.4 promediadas en el trimestre Nov.-Enero (NDE), temporada en que se verifica el máximo climatológico de los eventos extremos de ENOS.

Para cada estación se estratificó la serie de datos en cuartiles según dicho índice. A cada año climatológico (se consideraron años no calendario, Set.-Ago., de modo de capturar la evolución de los eventos y su impacto en Uruguay) se le asoció el cuartil correspondiente al trimestre NDE comprendido en dicho año. El primer cuartil (Q1) se corresponde con los eventos La Niña (fase fría extrema) y el cuarto (Q4) está asociado a los eventos El Niño (fase cálida extrema).

Luego, para cada cuartil, se calculó el ciclo medio anual para el año climatológico de los siguientes estadísticos considerando una ventana móvil centrada de +/- 30 días (periodos de 61 días):

- Parámetros del modelo Markov+Gamma.
- Precipitación diaria.
- Probabilidad de lluvia.
- Probabilidad, para cada día del año, de estar en una racha seca mayor a 20 y 30 días (ver definición en la sección 3.2).
- Probabilidad, para cada día del año, de estar en un evento lluvioso (ver definición en la sección 3.2).

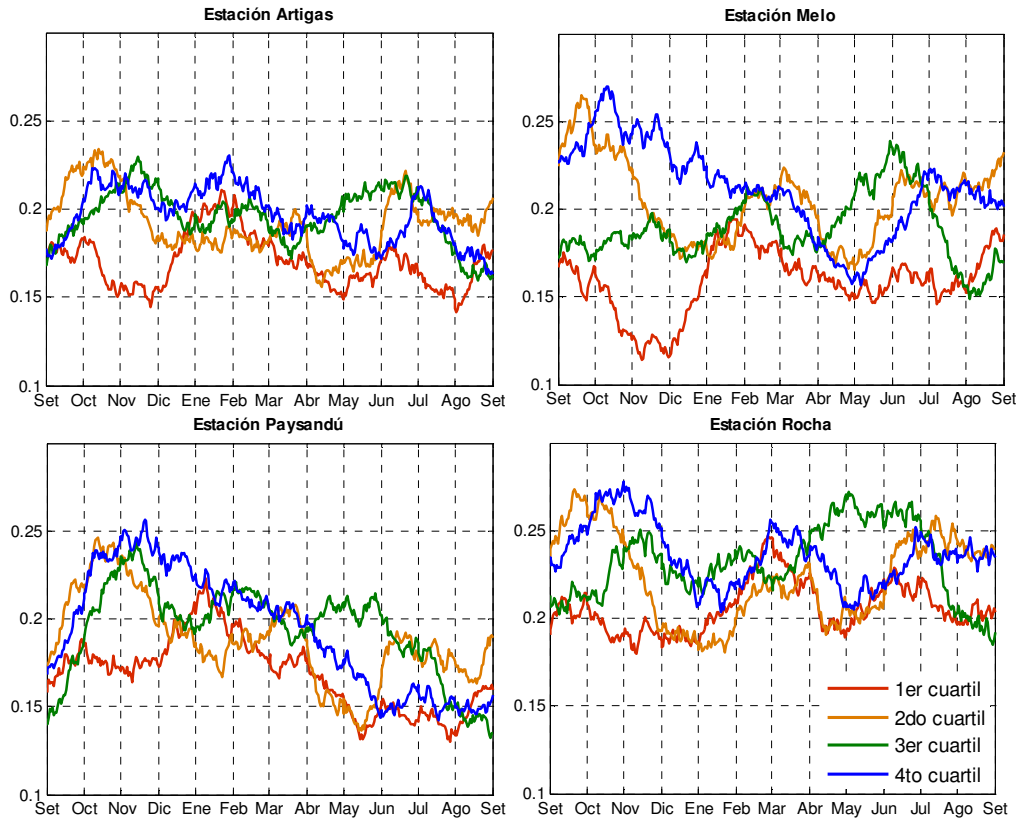
Los parámetros, además de su interés aplicado, pueden ser también relacionados con la naturaleza y frecuencia de los sistemas precipitantes

en una región dada. En este sentido, en la Figura 5-3 se presenta el ciclo medio anual por cuartil según el N3.4 de los parámetros del modelo para cuatro de las estaciones meteorológicas en las que se dispone de registros desde 1950 (Artigas, Paysandú, Melo y Rocha).

En general se observa que, con mayor o menor intensidad de la señal de ENOS, el Q1 (línea roja) se separa notoriamente en las probabilidades de que llueva condicionales a que llovió o no llovió el día anterior, mientras que el Q4 (línea azul) se aparta sustancialmente de los demás cuartiles en el parámetro β (sobre todo en las estaciones de la región noroeste). Dichos apartamientos se dan en la dirección esperada, el Q1 (eventos La Niña) tiene asociados sesgos a anomalías negativas de precipitación en Uruguay y el Q4 (eventos El Niño) a anomalías positivas. Para el parámetro α no se distingue un apartamiento claro entre los distintos cuartiles.

Cabe destacar que el análisis anterior no tiene un test estadístico asociado, por lo que no es posible afirmar si las diferencias identificadas entre los distintos cuartiles son estadísticamente significativas. Dichos test sí se implementarán para los estadísticos analizados sobre las series observadas y simuladas de precipitación.

Probabilidad de lluvia dado que no llovió (p_{01})



Probabilidad de lluvia dado que llovió (p_{11})

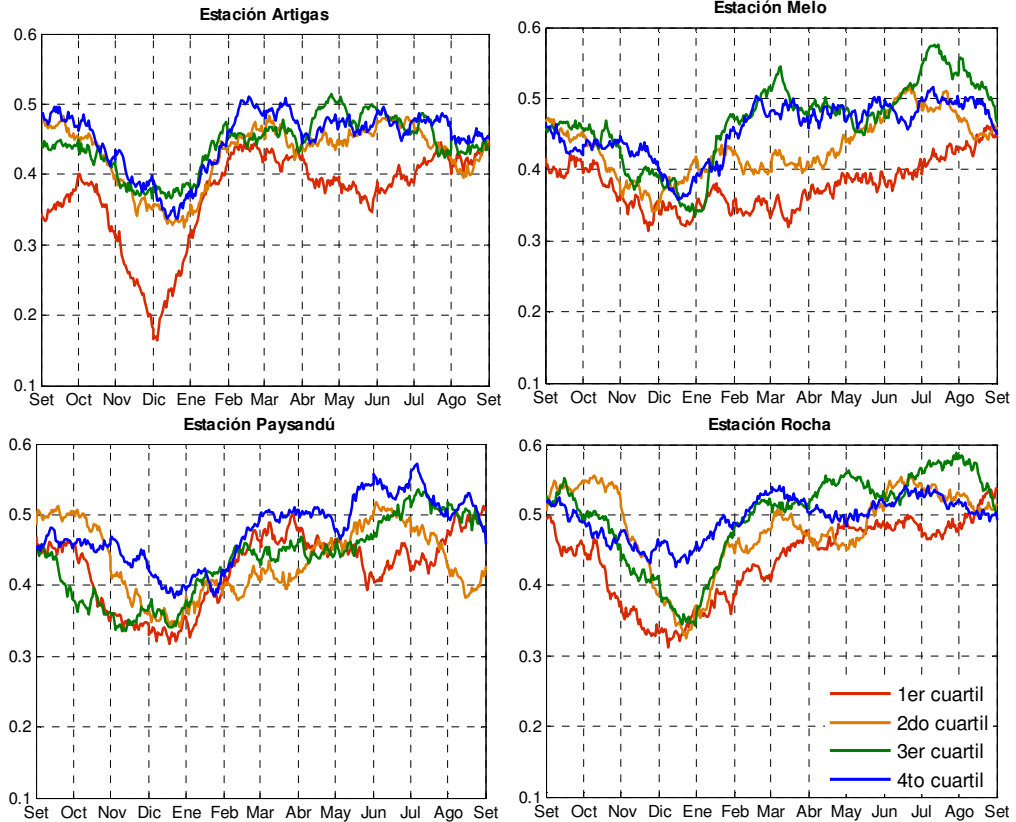
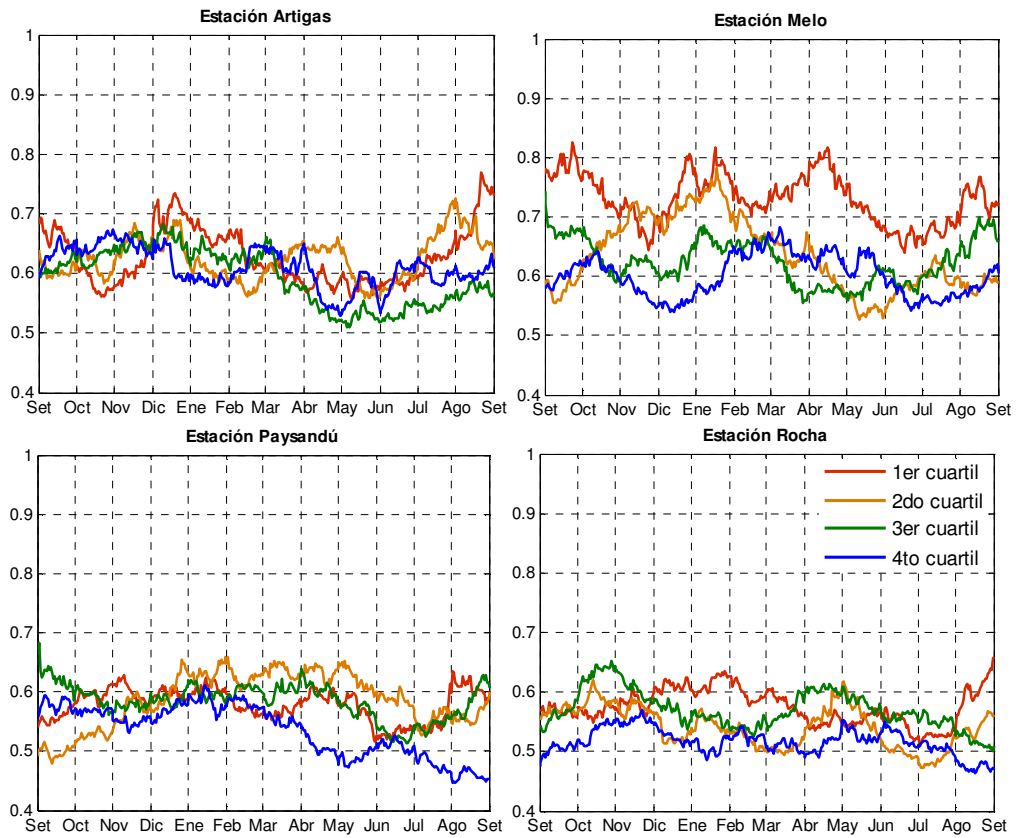


Figura 5-3a: Ciclo medio anual de los parámetros del modelo Markov+Gamma por cuartil según el índice N3.4.

Parámetro α



Parámetro β

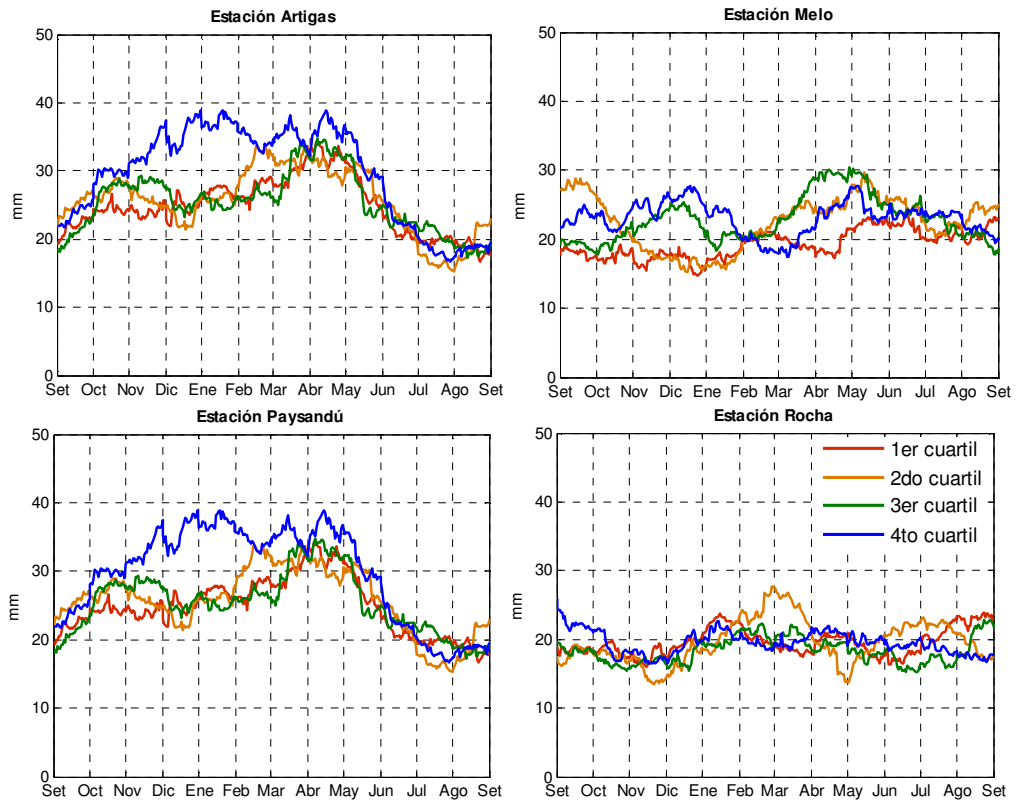


Figura 5-3b: Ciclo medio anual de los parámetros del modelo Markov+Gamma por cuartil según el índice N3.4.

La Figura 5-4 muestra el ciclo medio anual de precipitación diaria según si el mismo se estima a partir de todo el registro histórico disponible (media climatológica) o a partir de los muestreos condicionados por ENOS (considerando únicamente los años comprendidos dentro de Q1 y Q4). Además se calculó la significancia estadística mediante el método de Monte Carlo. Se hicieron 1.000 muestreos al azar de 15 años (igual cantidad que tienen Q1 y Q4) a partir del universo de 60. Se definieron entonces los umbrales de significancia de 5% y 95%, que indican la probabilidad de que por azar en un muestreo de 15 años (en 60) se obtengan precipitaciones por sobre (o debajo) de dichos valores en ausencia de sesgos climáticos.

Se presentan los resultados obtenidos para cuatro de las estaciones meteorológicas en las que se dispone de registros desde 1950 (Artigas, Paysandú, Melo y Rocha).

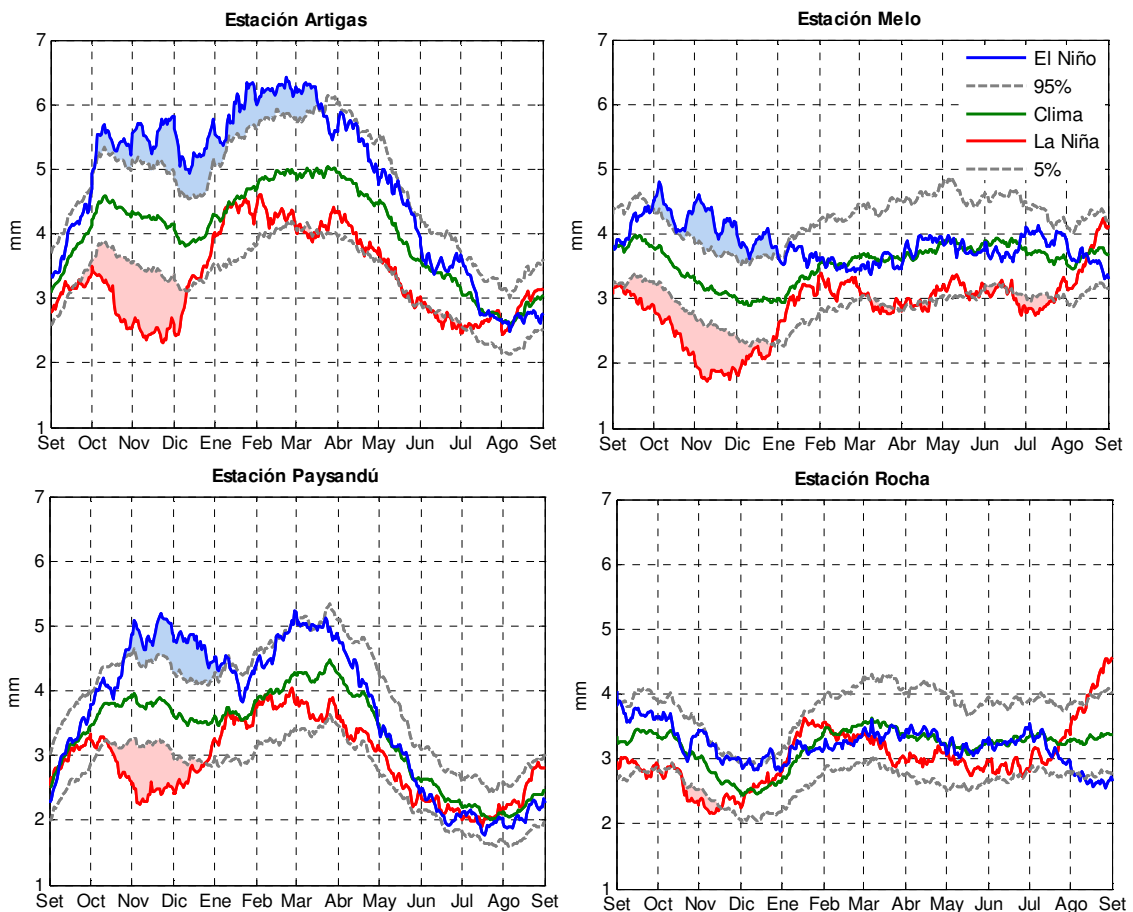


Figura 5-4: Ciclo medio anual de precipitación diaria: media climatológica (considerando todos los años) y muestreos condicionados por ENOS. Se indican los niveles de 5% y 95% de significancia estadística.

Se observa que, tal como era de esperar, a mayor índice N3.4 mayor precipitación, siendo los períodos más significativos (sombreados en color

celeste -El Niño- y en rosado -La Niña-) principalmente la primavera y el comienzo del verano. Dicho comportamiento, además de ser fuertemente estacional también varía espacialmente, presentando un gradiente de sureste a noroeste.

Análogamente en las siguientes figuras se presentan los resultados obtenidos para la probabilidad de lluvia, la probabilidad de estar en una racha seca mayor a 20 y 30 días y la probabilidad de estar en un evento lluvioso.

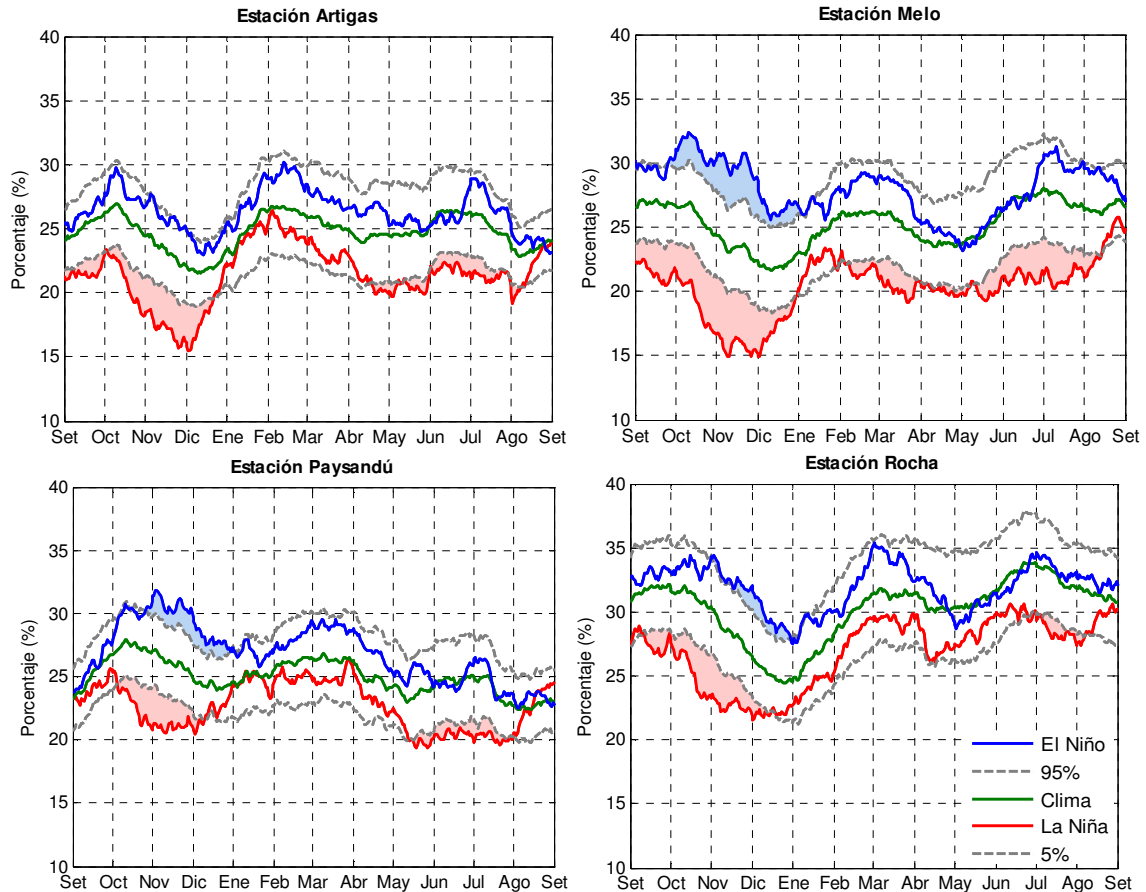


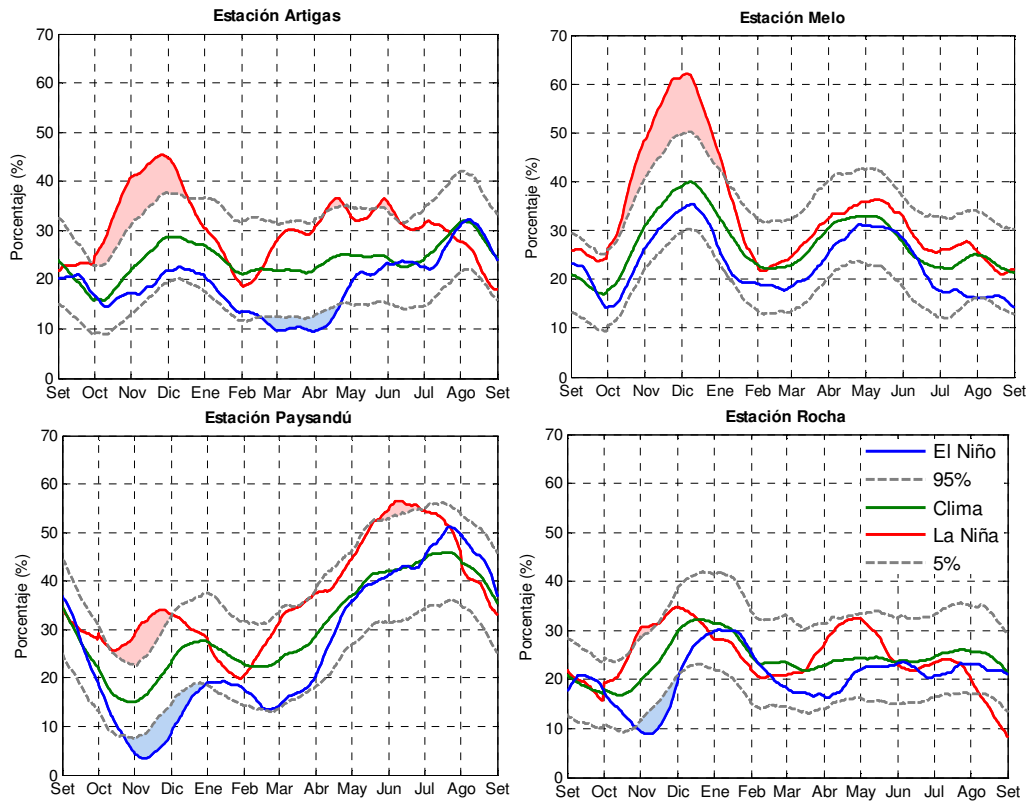
Figura 5-5: Ciclo medio anual de la probabilidad de lluvia: media climatológica (considerando todos los años) y muestreos condicionados por ENOS. Se indican los niveles de 5% y 95% de significancia estadística.

La Figura 5-5 es coherente con el comportamiento observado para el Q1 en el ciclo anual de los parámetros del modelo (mayor apartamiento en las probabilidades condicionales de lluvia). Si bien para el Q4 se tienen algunos períodos con sesgos en la probabilidad de lluvia significativos, el sesgo es notoriamente mayor para el Q1. A diferencia de la Figura 5-4 de precipitación media diaria, en que la señal significativa se limita casi exclusivamente a la primavera e inicio del verano, se verifican períodos significativos de menos días de lluvia de lo habitual para Q1 durante el

período Marzo-Julio en varios casos. Otra diferencia con la precipitación media es que las variaciones regionales de la señal de ENOS son menos notorias que cuando se consideran los montos, siendo la señal más intensa en Melo y no Artigas como en la Figura 5-4.

La Figura 5-6, que depende fundamentalmente de las frecuencias de lluvia, tiene características similares a la Figura 5-5.

Rachas mayores a 20 días



Rachas mayores a 30 días

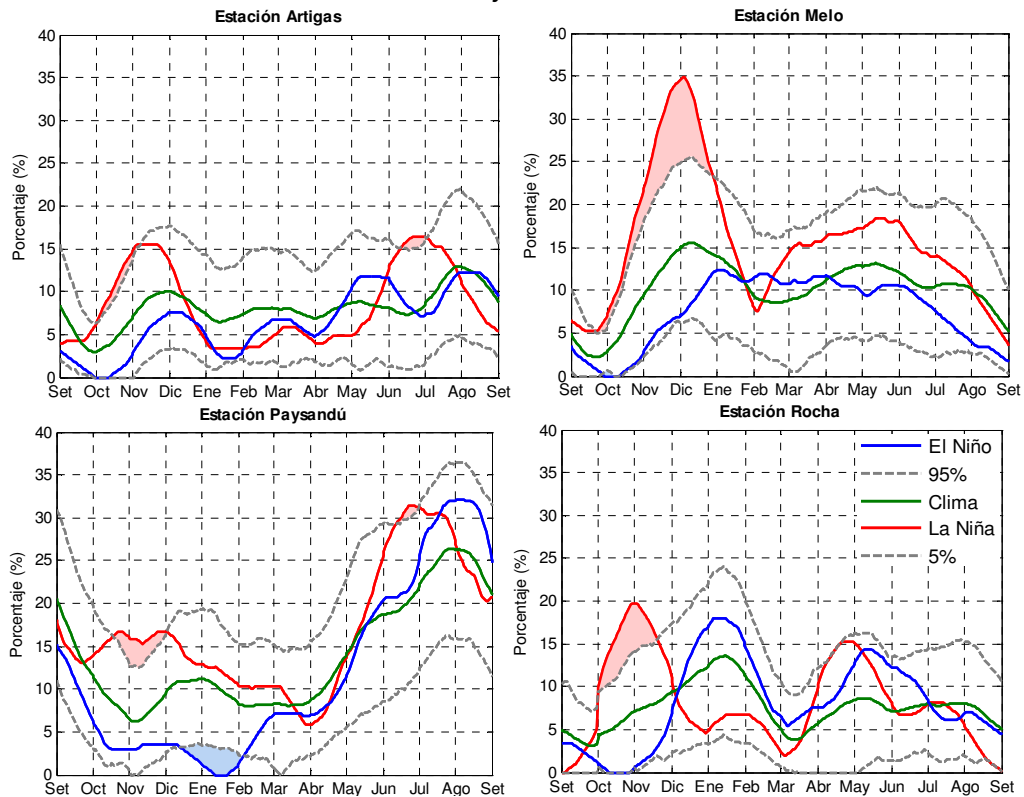


Figura 5-6: Ciclo medio anual de la probabilidad, para cada día del año, de estar en una racha seca mayor a 20 y 30 días: media climatológica (considerando todos los años) y en muestreos condicionados por ENOS. Se indican los niveles de 5% y 95% de significancia estadística.

En la Figura 5-7 se observa que la probabilidad de estar en un evento lluvioso hereda las características ya señaladas para el caso de la precipitación media. La señal más fuerte de ENOS (mayor índice N3.4, mayor precipitación) se da en Artigas.

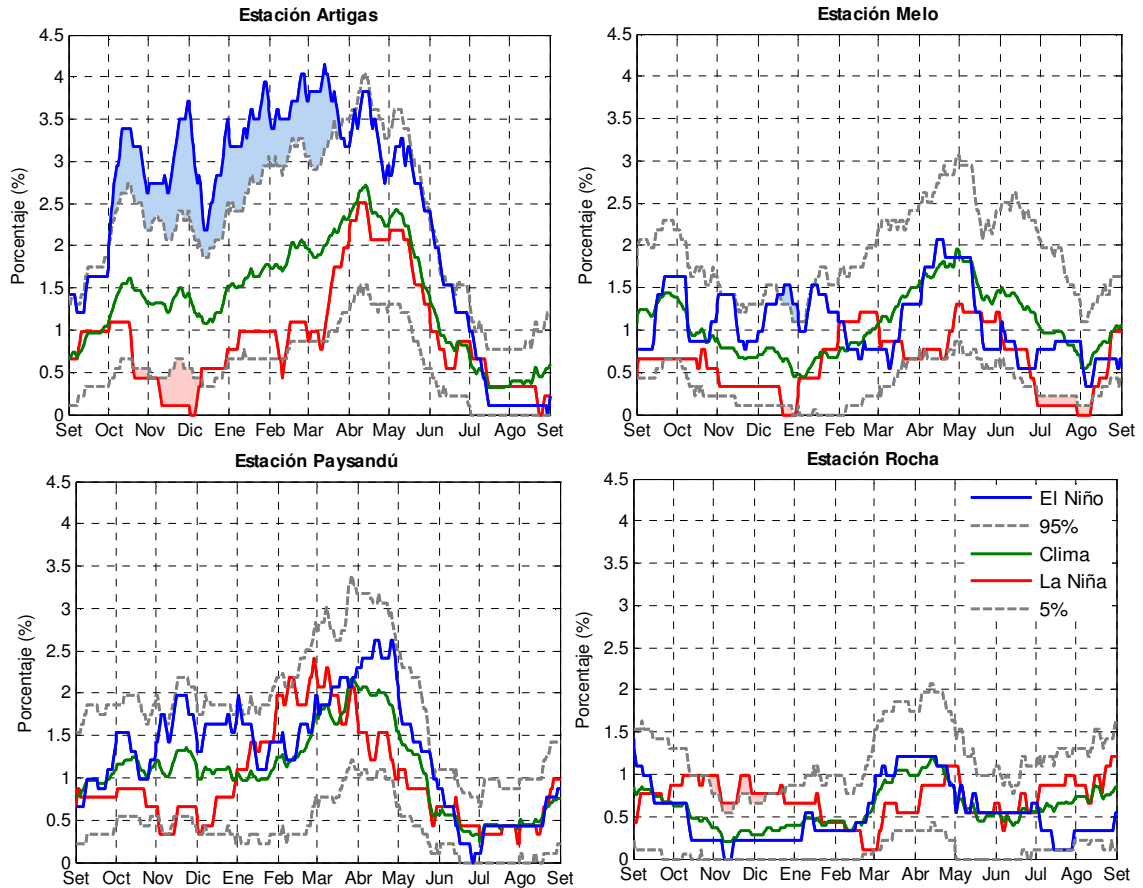


Figura 5-7: Ciclo medio anual de la probabilidad, para cada día del año, de estar en un evento lluvioso: media climatológica (considerando todos los años) y en muestreos condicionados por ENOS. Se indican los niveles de 5% y 95% de significancia estadística.

5.3 METODOLOGÍA

Se partió del generador Markov+Gamma con parámetros variables a lo largo del año y se le incorporó una variable de condicionamiento que permite remuestrear selectivamente los datos históricos de modo de producir secuencias sintéticas consistentes con un escenario determinado, en este caso asociados al fenómeno ENOS.

Tal como se mencionó anteriormente, como variable de condicionamiento se emplearon las anomalías del índice N3.4 promediadas en el trimestre NDE para años que van de setiembre a agosto.

A continuación se describe la metodología planteada, la que fue implementada en la plataforma MATLAB.

5.3.1 Estratificación por ENOS

Dada una serie de datos, se la estratificó en cuartiles según el índice N3.4 en el trimestre NDE. A cada año climatológico (Set.-Ago.) se le asoció el cuartil correspondiente al trimestre NDE comprendido en dicho año.

Luego, para cada cuartil según el índice N3.4, se calculó el ciclo anual de los parámetros del modelo Markov+Gamma considerando una ventana móvil centrada de +/- 30 días.

5.3.1 Generación de las series sintéticas

Una vez obtenido el set de parámetros para cada cuartil según el índice N3.4, se generaron cuatro series sintéticas de precipitación diaria de 250 años cada una (una serie con cada set de parámetros).

La serie sintética con ENOS (de 1.000 años de longitud) queda conformada por la unión de esas cuatro series. Como ninguno de los estadísticos analizados involucra variaciones multianuales, la unión puede ser realizada de cualquier manera sin afectar los resultados.

5.4 RESULTADOS

En primer lugar, a modo de verificación, se calculó para cada cuartil el ciclo medio anual de los parámetros del modelo Markov+Gamma calculados a partir de las series simuladas considerando una longitud de media ventana de 30 días.

Por ejemplo, en la Figura 5-8 se presentan los resultados obtenidos para la estación Artigas. Se observa que se recupera satisfactoriamente el ciclo medio anual de los parámetros del modelo que generó las propias series sintéticas.

Además, se comparó el ciclo medio anual de precipitación diaria obtenido en cada caso (Figura 5-9). Se observa que las series simuladas por cuartil según el índice N3.4 reproducen adecuadamente el ciclo medio anual de precipitación diaria de las series observadas condicionadas por ENOS.

Si bien se usó la misma longitud de ventana de muestreo para las series simuladas y las observadas, el ciclo anual de las series sintéticas es más suave debido a que en cada caso se simularon 250 años, en comparación con los $60/4 = 15$ años de las series históricas disponibles por cuartil.

Para el resto de las estaciones se obtuvo un comportamiento análogo.

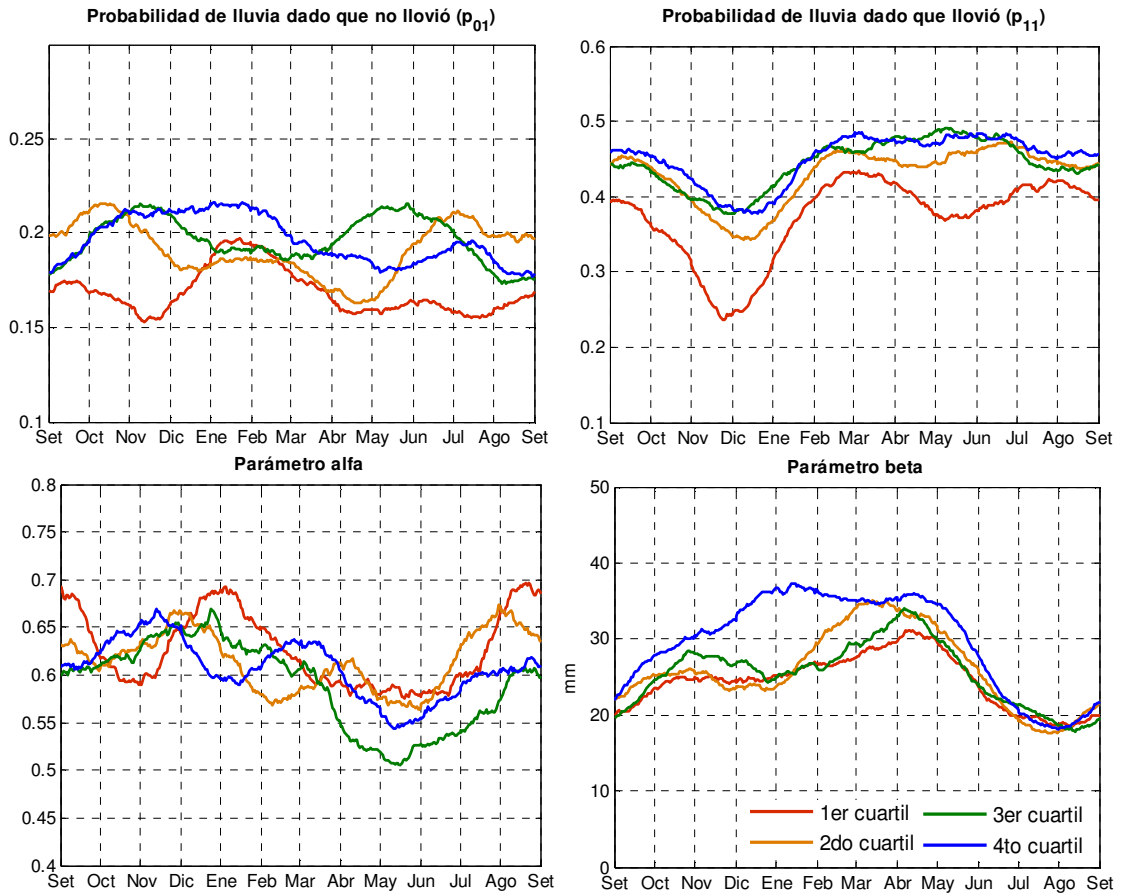


Figura 5-8: Ciclo medio anual de los parámetros del modelo Markov+Gamma de las series sintéticas por cuartil según el índice N3.4 (resultados obtenidos para la estación Artigas).




Figura 5-9: Comparación del ciclo medio anual de precipitación diaria de la serie observada y las series sintéticas por cuartil según el índice N3.4 (resultados obtenidos para la estación Artigas).

Luego, con el propósito de evaluar el efecto de la incorporación de sesgos climáticos al generador de tiempo en valores medios no condicionados, se

comparó el ciclo medio anual de los parámetros del modelo y de la precipitación diaria de la serie observada y las series simuladas con y sin ENOS (para una longitud de media ventana de 30 días).

A modo de ejemplo, en las Figura 5-10 y 5-11 se presentan los resultados obtenidos para la estación Artigas. Para el resto de las estaciones se obtuvo un comportamiento análogo.

Como era de esperar, no se observan diferencias significativas entre las series sintéticas con y sin ENOS en lo que refiere a la reproducción de los valores medios. Sí es de esperar, como se verá más adelante, que algunos aspectos de la variabilidad interanual mejoren.

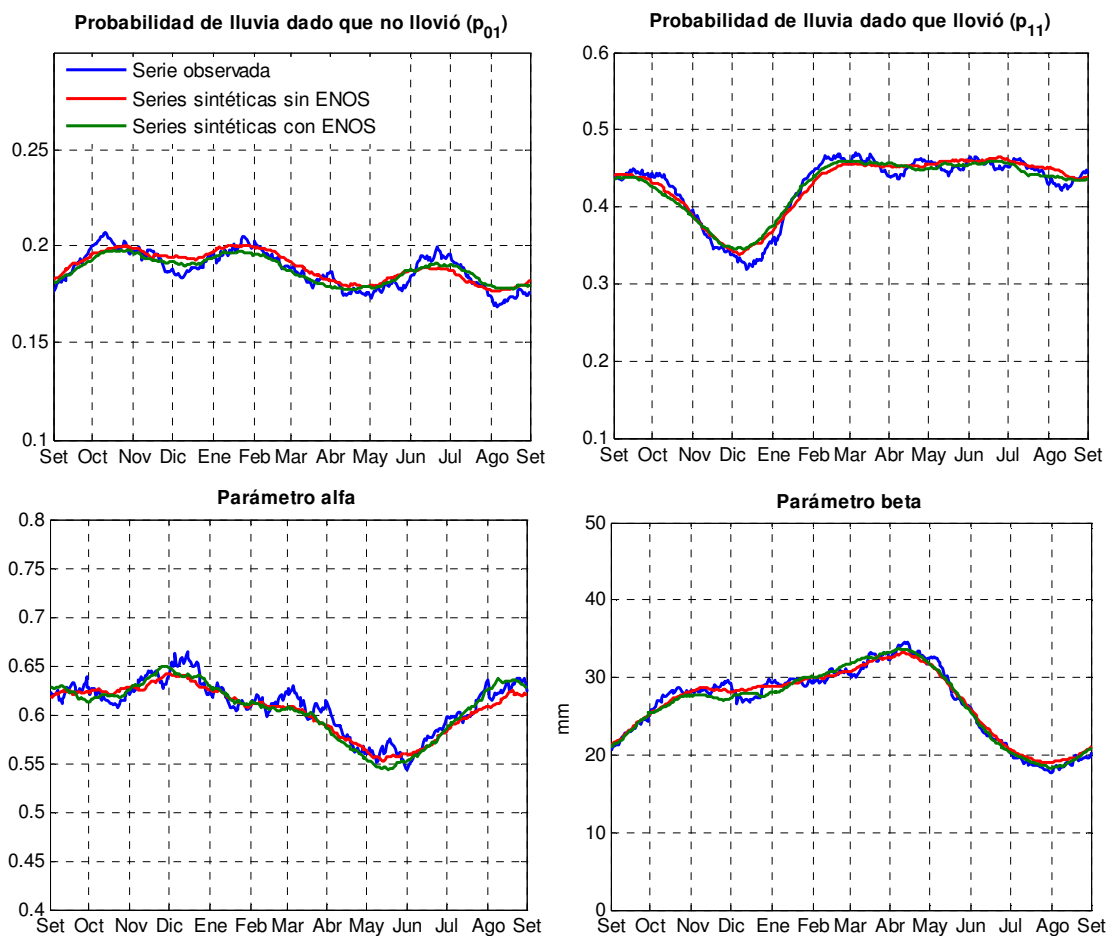


Figura 5-10: Comparación del ciclo medio anual de los parámetros del modelo Markov+Gamma de la serie observada y las series sintéticas con y sin ENOS (resultados obtenidos para la estación Artigas).




Figura 5-11: Comparación del ciclo medio anual de precipitación diaria de la serie observada y las series sintéticas con y sin ENOS (resultados obtenidos para la estación Artigas).

La Figura 5-12 muestra el ciclo medio anual para el año climatológico (Set.-Ago.) de precipitación diaria de las series sintéticas generadas con el set de parámetros Q1 (eventos La Niña) y Q4 (eventos El Niño). Además, se indica el ciclo anual mínimo y máximo de las series sintéticas sin ENOS, construidos de la siguiente manera:

- Se sortean 250 años de la serie sintética sin ENOS (de 1.000 años de longitud) y se calcula el ciclo medio anual de precipitación diaria a partir de dichos años.
- Se repite el procedimiento un número grande de veces (por ejemplo $N=100$), y se obtienen así, N ciclos anuales de precipitación diaria.
- Se selecciona, para cada día del año, el valor mínimo y máximo (de esos N valores) y se construye el ciclo anual mínimo y máximo a partir de medias de 250 años de las series sintéticas sin ENOS.

Si se aceptara que el set de parámetros por cuartil calculado en base a 15 años es representativo del mismo set de parámetros computado en 250 años, entonces dichas curvas (ciclo anual mínimo y máximo) se podrían interpretar como un umbral de significancia estadística de la señal de ENOS, análogamente a las Figuras 5-4 a 5-7. Estrictamente, la extrapolación propuesta no es válida y, entonces, dichas curvas no se pueden interpretar de esta forma.

Se presentan los resultados obtenidos para cuatro de las estaciones meteorológicas en las que se dispone de registros desde 1950 (Artigas, Paysandú, Melo y Rocha).

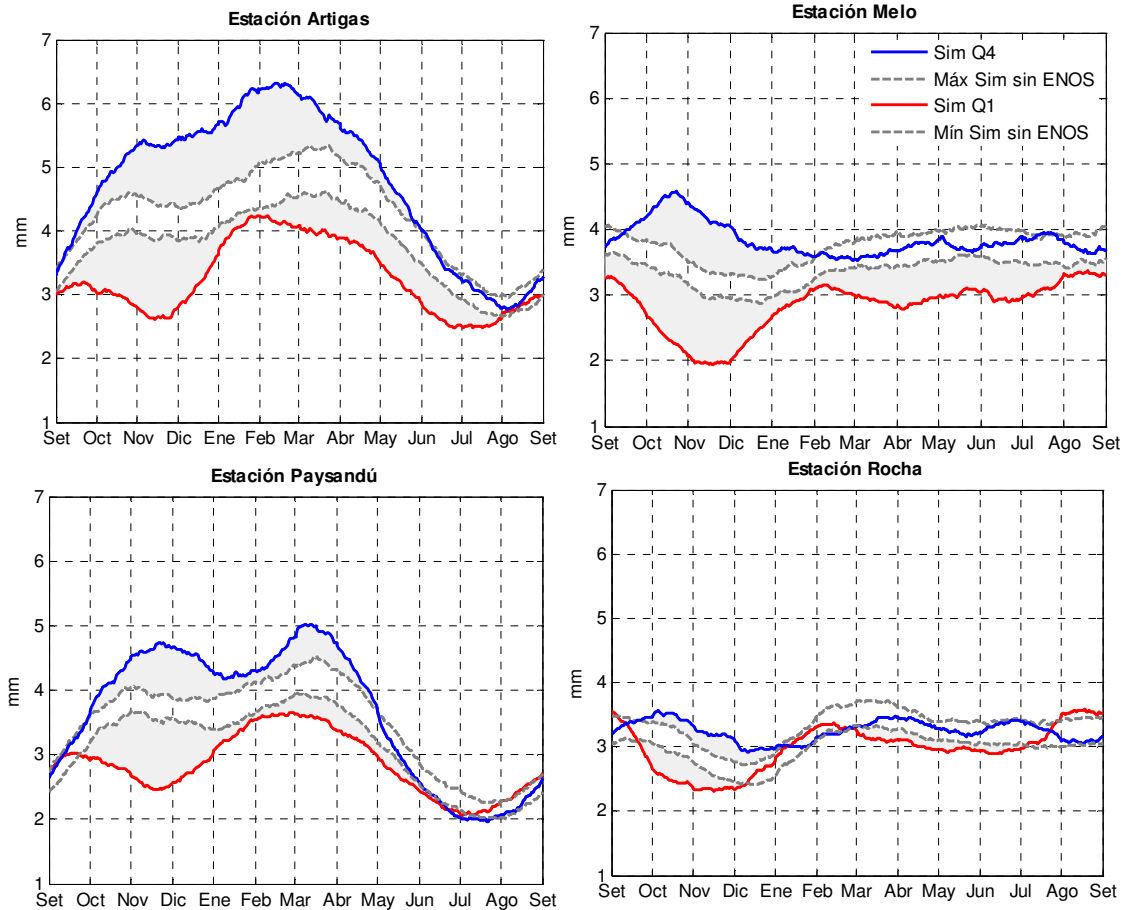


Figura 5-12: Ciclo medio anual de precipitación diaria calculado a partir de las series sintéticas: Q1 (Niña), Q4 (Niño), máximo y mínimo sin ENOS.

Análogamente en las siguientes figuras se presentan los resultados obtenidos para la probabilidad de lluvia, la probabilidad de estar en una racha seca mayor a 20 y 30 días y la probabilidad de estar en un evento lluvioso.

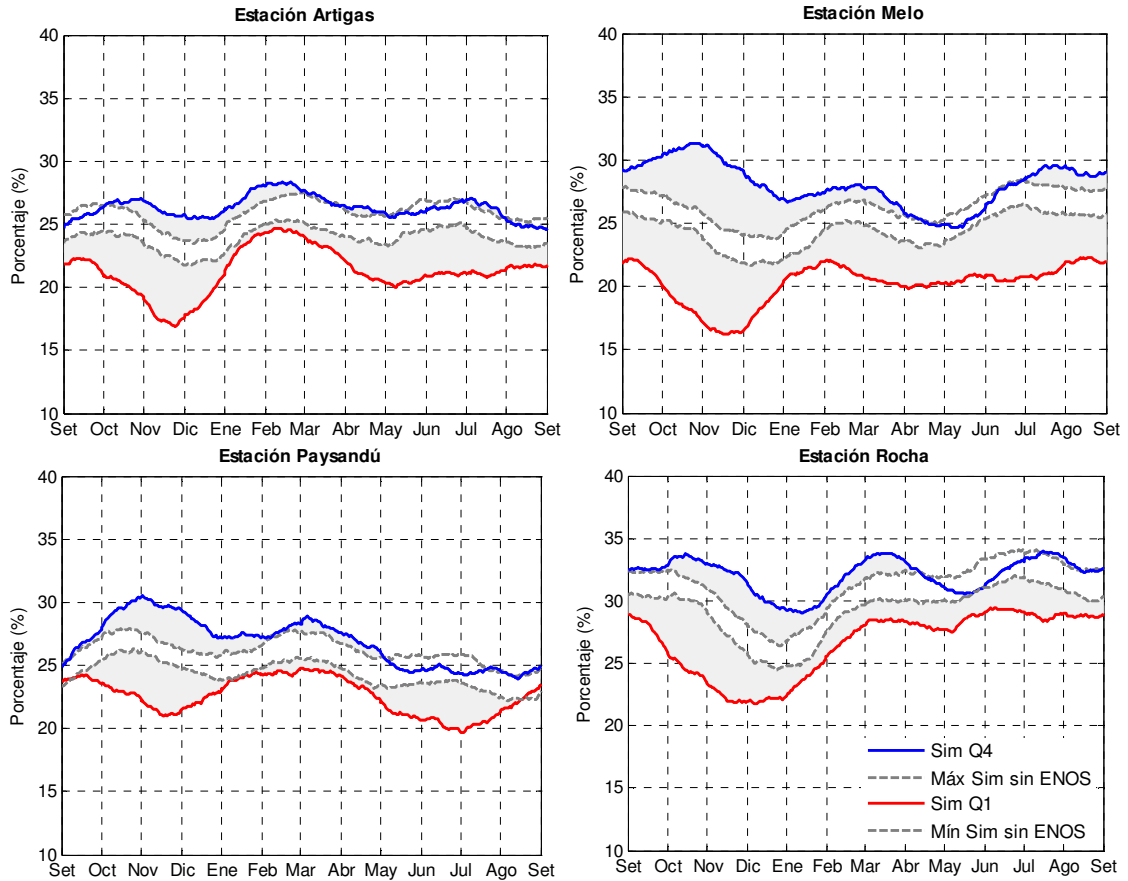
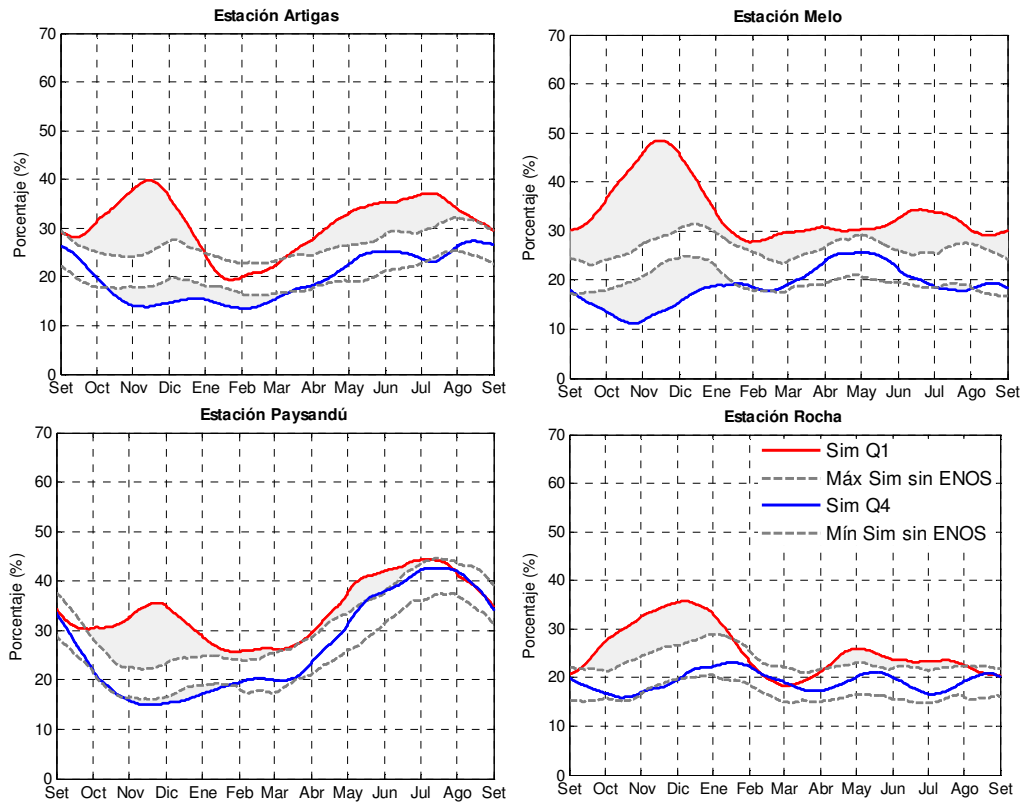


Figura 5-13: Ciclo medio anual de la probabilidad de lluvia calculado a partir de las series sintéticas: Q1 (Niña), Q4 (Niño), máximo y mínimo sin ENOS.

Rachas mayores a 20 días



Rachas mayores a 30 días

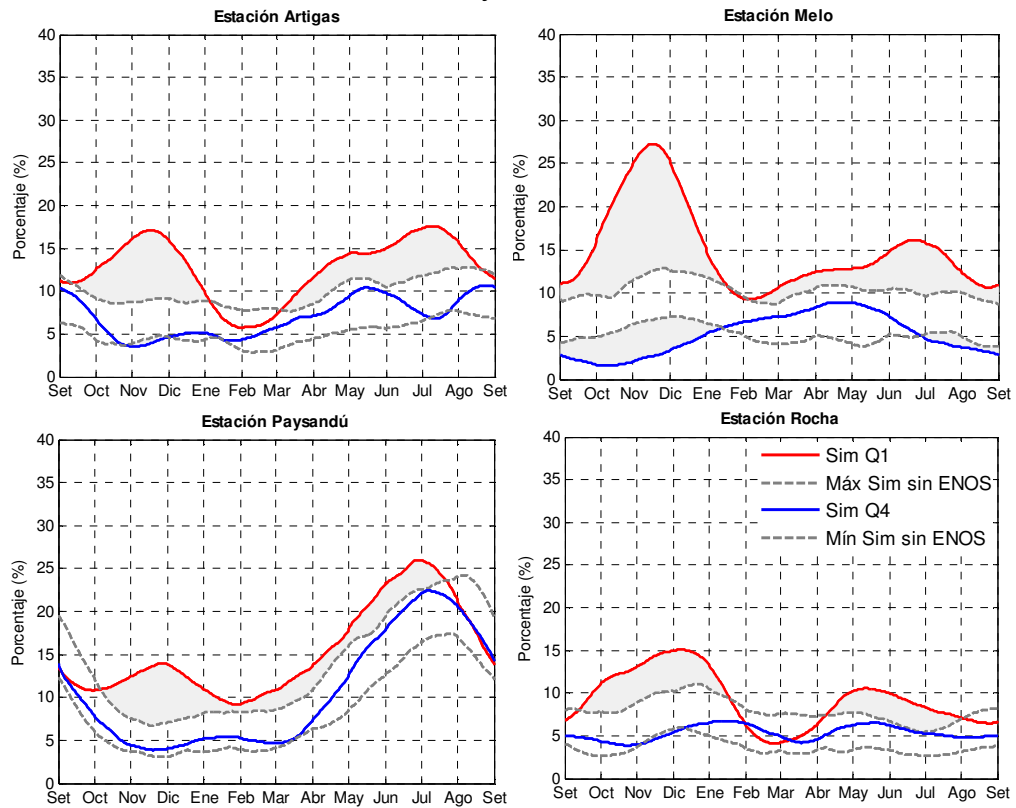


Figura 5-14: Ciclo medio anual de la probabilidad, para cada día del año, de estar en una racha seca mayor a 20 y 30 días calculado a partir de las series sintéticas: Q1 (Niña), Q4 (Niño), máximo y mínimo sin ENOS.

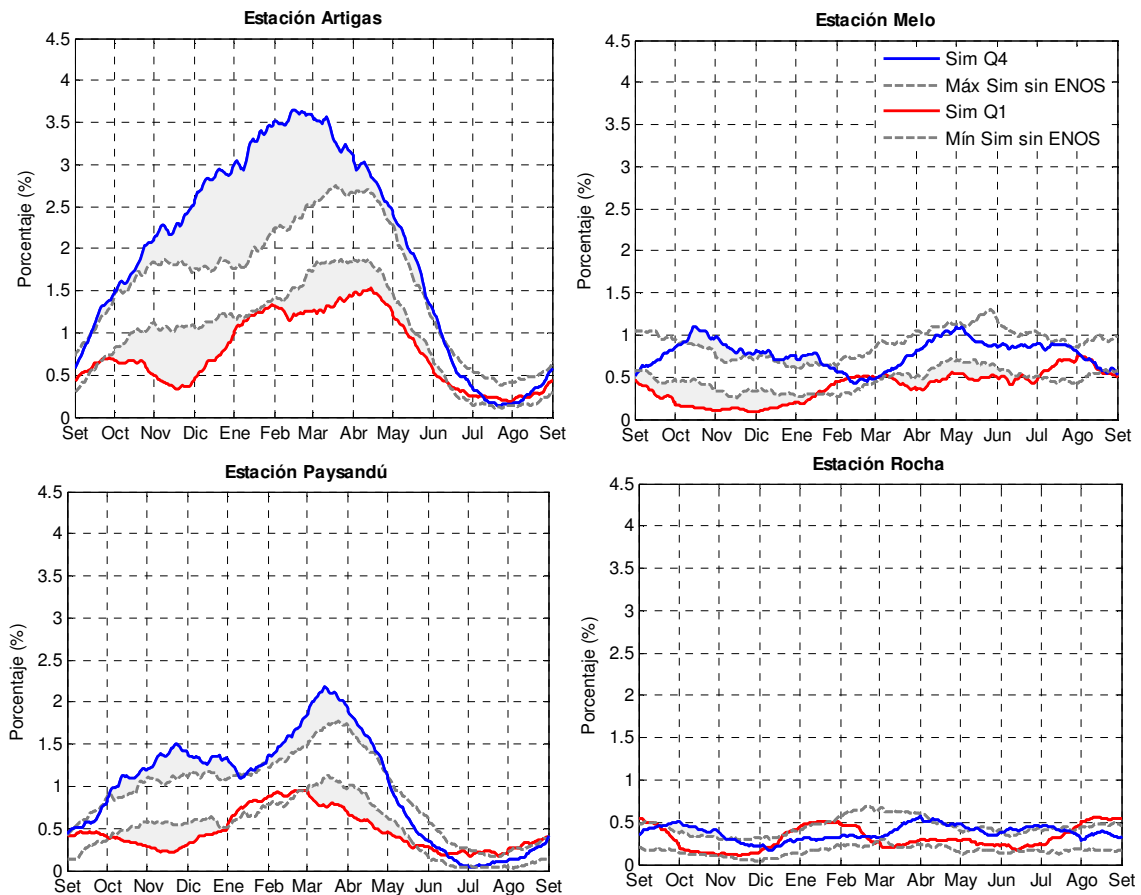


Figura 5-15: Ciclo medio anual de la probabilidad, para cada día del año, de estar en un evento lluvioso calculado a partir de las series sintéticas: Q1 (Niña), Q4 (Niño), máximo y mínimo sin ENOS.

Como es de esperar dada la metodología empleada, las Figuras 5-12 a 5-15 reproducen la señal ya descrita en las Figuras 5-4 a 5-7 pero con mayor claridad dado la mayor suavidad de las curvas que genera el mayor número de años. La contracara es que, como ya se ha señalado, el área sombreada no puede ser interpretada como la de significancia estadística en el mismo sentido que en las Figuras 5-4 a 5-7. Se presentan igual pues dan una idea de la significancia estadística que tomaría la señal de ENOS, si el impacto del condicionamiento en la serie disponible que genera el set de parámetros calculados se mantuviera en registros más largos.

Finalmente, para evaluar el efecto de la incorporación de sesgos climáticos en la reproducción de la variabilidad interanual, se construyeron los histogramas de precipitación acumulada mensual, trimestral y anual de la serie observada y las series sintéticas con y sin ENOS.

A modo de ejemplo, en la Figura 5-16 se presentan los resultados obtenidos para la estación Artigas. Para el resto de las estaciones se obtuvo un comportamiento análogo.

Se observa que la incorporación de sesgos climáticos mejora marginalmente el desempeño del modelo en las colas de los histogramas (acumulados de precipitación muy bajos o muy altos).




Figura 5-16: Histogramas de precipitación acumulada mensual, trimestral y anual de la serie observada y las series sintéticas con y sin ENOS (resultados obtenidos para la estación Artigas).

5.5 CONCLUSIONES

En primer lugar se realizó una caracterización de la señal de ENOS en estadísticos de precipitación a partir de datos diarios, donde se obtuvieron varios resultados novedosos: la identificación de los períodos de señal independizados de los meses calendario, la separación del sesgo en montos y en frecuencia de lluvia y las diferencias regionales en ambos sesgos.

Se propuso luego una metodología para la incorporación de sesgos climáticos al generador de tiempo Markov+Gamma, mediante una variable de condicionamiento que permite remuestrear selectivamente los datos históricos de modo de producir secuencias sintéticas consistentes con un escenario determinado.

Los resultados obtenidos muestran que el procedimiento desarrollado logra capturar satisfactoriamente la señal de ENOS, siendo clara su influencia sobre el régimen de precipitación, sobre todo durante las fases extremas, El Niño y la Niña. Esto resulta muy interesante ya que plantea la posibilidad de prever sesgos en la distribución esperada de la lluvia empleando como predictor el ENOS, predictor climático más importante de la precipitación en Uruguay, sobre todo considerando la existencia de numerosos modelos que pronostican exitosamente el índice N3.4 hasta con un año de antelación.

CAPÍTULO 6

CO-VARIABILIDAD ESPACIAL

6. Co-variabilidad espacial

Para muchas aplicaciones hidrológicas, en particular, cuando se trata de cuencas de cierta extensión, es necesario representar correctamente la correlación espacial entre pluviómetros.

Surge entonces el desafío de implementar un generador de clima multipunto, que preserve las correlaciones espaciales entre las distintas estaciones.

6.1 ANTECEDENTES

Según Baigorria (2010), los generadores de clima multipunto se pueden clasificar como **paramétricos** (Wilks, 1998; Qian et al., 2002; Brissette et al., 2007; Khalili et al., 2007; Leander y Buishand, 2009; Srikanthan y Pegram, 2009), **no paramétricos** (Beersma y Buishand, 2003; Wilby et al., 2003; Burton et al., 2008) e **híbridos** (Palutikof et al., 2002; Fowler et al., 2005; Apipattanavis et al., 2007; Cannon, 2008).

Muchos modelos paramétricos se basan total o parcialmente en el modelo de Wilks (1998), incluyendo el desarrollado en el presente trabajo de tesis. La mayoría de los modelos no paramétricos se basan en métodos de remuestreo de los K vecinos más cercanos ("K-Nearest Neighbours", KNN). Mehrotra et al. (2006) comparó un modelo multipunto paramétrico contra uno no paramétrico, llegando a la conclusión de que el modelo de Wilks se comporta mejor que el método KNN, aunque ninguno de los dos modelos logra reproducir las características de largo plazo.

Una limitación de los modelos paramétricos es que al aumentar el número de estaciones de la red, el número de parámetros del modelo crece casi exponencialmente (Mehrotra et al., 2006).

La Figura 6-1 muestra, en orden cronológico, algunos ejemplos de generadores de tiempo multipunto desarrollados por diversos autores.

TABLE 1. Comparison of structures and mathematical algorithms of multisite weather generator models.

Authors	Description
Wilks (1998)	Parametric model: Empirically derived curves for each pairwise weather station to relate the needed correlation of random numbers to the observed correlation. Cholesky factorization of the correlation matrix multiplied by a matrix of random numbers. Results transformed to events by a Markovian process. Mixed exponential distribution for nonzero rainfall amounts along with spatially correlated random numbers from a multivariate normal distribution.
Beersma and Buishand (2003)	Nonparametric model: K-nearest neighbor resampling time series bootstrapping from historical observations.
Palutikof et al. (2002)	Hybrid parametric and nonparametric model: Generation of a first weather station conditioned on a first-order Markovian process followed by uniform random sampling of multisite rainfall scenarios predefined by circulation weather types.
Qian et al. (2002)	Parametric model: Use of atmospheric circulation patterns to calibrate parameters of the probability distributions in the Wilks (1998) weather generator.
Wilby et al. (2003)	Nonparametric model: Generation of series of areal average amounts across multiple sites conditional on a set of large-scale daily circulation patterns followed by resampling the historical record.
Fowler et al. (2005)	Hybrid model: Neyman–Scott rectangular pulses stochastic rainfall models conditioned with a semi-Markov-based weather generator using parameters fitted by Monte Carlo simulations.
Khalili et al. (2007)	Moran's I autocorrelation index and moving average process to generate spatially autocorrelated random numbers.
Apipattanavis et al. (2007)	Hybrid parametric and nonparametric models: Markov chains to capture the dry and wet spell statistics to use in a stochastic daily weather generator. A K-nearest neighbor bootstrap resampling method captured the distributional and lag-dependence statistics of rainfall.
Brissette et al. (2007)	Parametric model: Basic simplex optimization process of the Wilks (1998) approach using a perturbation equation based on a convergence criterion to modify the observed correlation matrix.
Burton et al. (2008)	Nonparametric model. Multisite time series sampled from a spatial–temporal Neyman–Scott rectangular pulses process (Rodriguez-Iturbe et al. 1987).
Cannon (2008)	Hybrid regression–nonparametric model: Expanded Bernoulli–Gamma density network (EBDN), based on artificial neural networks conditioned to density estimation in conjunction with the Bernoulli–gamma distribution.
Leander and Buishand (2009)	Nonparametric model: Two-stage time series resampling algorithm to simulate daily values of rainfall composed of an expected value and a sampled historical residual. K-nearest neighbor in conjunction with first-order autoregressive models (lognormal and exponential).
Srikanthan and Pegram (2009)	Parametric model: Fourth-order Markov chain combined with a Wilks (1998) model.
Baigorria and Jones (this paper)	Parametric model: Orthogonal Markov chain and multiensemble realizations for rainfall events. Wilks (1998) approach for rainfall amounts using the correlation matrix of the transformed gamma to Gaussian daily rainfall amounts.

Figura 6-1: Estructura de algunos generadores de tiempo multipunto.
(Fuente: Baigorria, 2010)

6.2 METODOLOGÍA

Se partió del generador Markov+Gamma con parámetros variables a lo largo del año (p_{11} , p_{01} , α y β) y se lo modificó de forma tal de generar un conjunto de modelos individuales (puntuales) con sorteos aleatorios temporalmente independientes pero espacialmente correlacionados, mediante una simulación simultánea de secuencias de tiempo en múltiples puntos. Debido a que las distribuciones marginales de estos números aleatorios son las mismas que en el modelo puntual, se conservan los comportamientos individuales de los modelos locales. Sin embargo, la correlación espacial en la secuencia de números aleatorios conduce a correlaciones espaciales en las series sintéticas que imitan las de las observaciones.

A continuación se describe la metodología planteada, basada en el trabajo de Wilks (1998), la cual fue implementada en la plataforma MATLAB.

6.2.1 Ocurrencia de precipitación

Dada una red de n estaciones, hay $n(n-1)/2$ combinaciones de pares de estaciones e igual número de correlaciones entre los elementos del vector de forzamiento \vec{w}_t (que se introduce en la ecuación [6-1]) que deben determinarse para simular la ocurrencia de precipitación en la red.

El problema de encontrar estas correlaciones se simplifica por el hecho de que los procesos de ocurrencia de precipitación se puede simular directamente a través de variables normales estándar (en lugar de variables aleatorias uniformes), según:

$$X_t(k) = \begin{cases} 1, & \text{si } w_t(k) \leq \Phi^{-1}[p_c(k)] \\ 0, & \text{en otro caso} \end{cases} \quad [6-1]$$

Donde:

$X_t(k)$: Evento binario de lluvia o no lluvia en el día t en la estación k

$$X_t(k) = \begin{cases} 0 & \text{si } t \text{ es un día seco en la estación } k \\ 1 & \text{si } t \text{ es un día lluvioso en la estación } k \end{cases}$$

$w_t(k)$: Realización de la variable normal estándar para el día t en la estación k .

$\Phi[\cdot]$: Función de distribución acumulada normal estándar.

p_c : Probabilidad crítica, según:

$$p_c(k) = \begin{cases} p_{01}(k), & \text{si } X_{t-1}(k) = 0; \quad p_{01}(k) = Pr\{X_t(k) = 1 | X_{t-1}(k) = 0\} \\ p_{11}(k), & \text{si } X_{t-1}(k) = 1; \quad p_{01}(k) = Pr\{X_t(k) = 1 | X_{t-1}(k) = 1\} \end{cases}$$

Sea $\omega(k, l)$ la correlación entre pares de w_t para el par de estaciones k y l , según:

$$\omega(k, l) = Corr[w_t(k), w_t(l)]$$

Dados p_{11} y p_{01} para las estaciones k y l , un $\omega(k, l)$ en particular dará lugar a una correlación correspondiente entre las series binarias sintéticas para los dos sitios,

$$\xi(k, l) = Corr[X_t(k), X_t(l)]$$

Sea, además, $\xi^0(k, l)$ la correlación estimada a partir de las series binarias observadas $X_t^0(k)$ y $X_t^0(l)$ para las estaciones k y l .

El primer aspecto del problema de generación de precipitación multipunto se resuelve mediante la búsqueda de forma individual de los $n(n-1)/2$ pares de correlaciones $\omega(k, l)$ que, junto con los pares correspondientes de las probabilidades de transición, reproducen $\xi(k, l) = \xi^0(k, l)$ para cada par de estaciones. El cálculo directo de $\omega(k, l)$ a partir de $\xi^0(k, l)$ no es posible. Sin embargo, dados dos pares de probabilidades de transición $[p_{01}(k), p_{11}(k)]$ y $[p_{01}(l), p_{11}(l)]$, se encuentra empíricamente que existe una relación monótona creciente entre $\omega(k, l)$ y la resultante $\xi(k, l)$. Por lo

tanto, es posible hallar el valor de $\omega(k, l)$ mediante el método de bipartición.

Puesto que $\xi(\omega)$ se evalúa en cada iteración con una simulación estocástica, resultados más estables se logran mediante el uso de series sintéticas largas, y empezando cada nueva evaluación de $\xi(\omega)$ con la misma semilla ("seed") de números aleatorios. En este caso, se consideraron series sintéticas de 1000 años de longitud.

La Figura 6-2 muestra la relación entre las correlaciones $\omega(k, l)$ y $\xi(k, l)$ para las estaciones Artigas y Melo (ubicadas a 310 km de distancia entre sí), calculada considerando las probabilidades de transición diarias de cada estación durante el semestre Abril-Set. Se observa que la curva resultante pasa por el origen, ya que variables independientes de forzamiento producirán series sintéticas independientes, y se eleva a un máximo de $\xi_{max}(k, l) = 0,951$ cuando las cadenas de Markov para los dos sitios son forzados con números aleatorios idénticos. Para estas dos estaciones, en el semestre Abril-Set, la correlación observada $\xi^0(k, l)$ es de 0,607 y los modelos de Markov reproducen esta correlación cuando son forzados por un ruido bivariado gaussiano estándar de $\omega(k, l) = 0,845$.




Figura 6-2: Ilustración de la relación entre las correlaciones $\omega(k, l)$ y $\xi(k, l)$ para el semestre Abril-Setiembre (temporada fría) entre las estaciones Artigas y Melo.

Las realizaciones del vector w_t son generadas a partir de la distribución normal multivariada con media el vector nulo $\vec{0}$ y matriz de varianza-covarianza $[\Omega]$, cuyos elementos son las correlaciones $\omega(k, l)$. Los valores individuales de $w_t(k)$ siguen una distribución normal estándar (univariada), y en consecuencia se puede utilizar la ecuación [6-1] para generar las series temporales de ocurrencia de precipitación $X_t(k)$.

Por construcción, cada serie sintética $X_t(k)$ seguirá necesariamente la cadena de Markov definida por las probabilidades de transición $p_{11}(k)$ y $p_{01}(k)$, de modo que cada serie también respetará la frecuencia relativa global correcta de días lluviosos.

Cabe destacar que se realizaron análisis diferenciales para el semestre Abril-Set. (temporada fría) y Oct.-Marzo (temporada cálida), considerando que los mecanismos de lluvia son distintos y por tanto la correlación espacial de la precipitación potencialmente también. De contar con series más largas se podría fraccionar el año en mayor número de períodos.

6.2.2 Cantidad de precipitación

De forma análoga a la presentada para la ocurrencia de precipitación, es posible hallar la cantidad de precipitación de los días lluviosos a partir de la distribución normal multivariada con media el vector nulo $\vec{0}$ y matriz de varianza-covarianza $[Z]$, cuyos elementos son las correlaciones $\omega(k, l)$ tal que:

$$\text{Corr}[Y_t(k), Y_t(l)] = \text{Corr}[Y_t^0(k), Y_t^0(l)]$$

Donde $Y_t(k)$ y $Y_t^0(k)$ representan las series de montos de precipitación (cuando en ambas estaciones son simultáneamente distintos de cero) de las series simuladas y observadas respectivamente.

A partir del vector \vec{z}_t , que contiene las realizaciones de la variable normal estándar para cada estación, se obtienen las series temporales de montos de precipitación $Y_t(k)$, según:

$$Y_t(k) = F^{-1}[z_t(k), \alpha_t(k), \beta_t(k)]$$

Donde:

F : Función de distribución gamma acumulativa de parámetros $\alpha_t(k)$ y $\beta_t(k)$ para el día t en la estación k .

$z_t(k)$: Realización de la variable normal estándar para el día t en la estación k .

Finalmente, a partir de las series $X_t(k)$ e $Y_t(k)$ se obtiene la serie de precipitación diaria para la estación k , $P_t(k)$:

$$P_t(k) = Y_t(k) X_t(k)$$

Donde:

$X_t(k)$: Serie temporal de ocurrencia de precipitación para la estación k .

$Y_t(k)$: Serie temporal de montos de precipitación para la estación k .

6.3 RESULTADOS

A modo de ejemplo, en la Figura 6-3 se presentan las matrices de correlaciones de ocurrencia $[\Omega]$ y montos de precipitación $[Z]$ entre las cuatro estaciones meteorológicas seleccionadas, obtenidas según el procedimiento anterior (de forma tal que las correlaciones espaciales de las series sintéticas reproducen las de las observaciones). La entrada i, j corresponde a la correlación entre las estaciones i y j , siendo 1: Artigas, 2: Paysandú, 3: Melo y 4: Prado.

Cabe destacar que en el caso de la ocurrencia de precipitación el cálculo se realizó a partir de 5.000 datos aproximadamente; mientras que para los montos, dado que se deben considerar únicamente los días en que llovió simultáneamente en ambas estaciones, se dispuso del orden de 900 datos para cada par de estaciones.

$$\begin{array}{cc}
 \text{Temporada fría} & \text{Temporada cálida} \\
 [\Omega]^{Abr-Set} = \begin{pmatrix} 1 & 0,524 & 0,607 & 0,340 \\ 0,524 & 1 & 0,540 & 0,477 \\ 0,607 & 0,540 & 1 & 0,439 \\ 0,340 & 0,477 & 0,439 & 1 \end{pmatrix} & [\Omega]^{Oct-Mar} = \begin{pmatrix} 1 & 0,496 & 0,523 & 0,297 \\ 0,496 & 1 & 0,501 & 0,465 \\ 0,523 & 0,501 & 1 & 0,394 \\ 0,297 & 0,465 & 0,394 & 1 \end{pmatrix} \\
 [Z]^{Abr-Set} = \begin{pmatrix} 1 & 0,268 & 0,365 & 0,059 \\ 0,268 & 1 & 0,261 & 0,223 \\ 0,365 & 0,261 & 1 & 0,108 \\ 0,059 & 0,223 & 0,108 & 1 \end{pmatrix} & [Z]^{Oct-Mar} = \begin{pmatrix} 1 & 0,169 & 0,272 & 0,090 \\ 0,169 & 1 & 0,259 & 0,242 \\ 0,272 & 0,259 & 1 & 0,221 \\ 0,090 & 0,242 & 0,221 & 1 \end{pmatrix}
 \end{array}$$

Figura 6-3: Matrices de correlaciones de ocurrencia $[\Omega]$ y montos de precipitación $[Z]$ entre las cuatro estaciones meteorológicas seleccionadas (Artigas, Paysandú, Melo y Prado).

Se observa que en general (excepto para la última columna de las matrices de montos $[Z]$) las correlaciones entre las distintas estaciones son menores en la temporada cálida (Oct.-Marzo), cuando son más frecuentes los sistemas precipitantes de origen convectivo de menor escala espacial.

Finalmente, en la Figura 6-4 se presenta la correlación entre las series observadas de ocurrencia y montos de precipitación en función de la distancia entre estaciones, diferenciando entre la temporada fría y la temporada cálida.

En algunos casos los valores de correlación (simultánea) obtenidos son relativamente bajos, lo cual se debe a que las distancias entre las estaciones asociadas son grandes (entre 240 y 500 km). Podría ser interesante, a medida que aumenta la distancia entre estaciones, considerar la correlación desfasada entre las series (un día en una estación con el siguiente en otra) de modo de capturar estadísticamente la evolución

espacial del sistema precipitante. No se dio dicho paso en esta primera etapa de desarrollo.




Figura 6-4: Correlación entre las series observadas de ocurrencia y montos de precipitación en función de la distancia entre estaciones para el semestre Abril-Set. (temporada fría) y Oct.-Marzo (temporada cálida).

6.4 CONCLUSIONES

A partir del generador puntual “Markov+Gamma” con parámetros variables a lo largo del año se implementó un modelo multipunto que reproduce las correlaciones espaciales (simultáneas) observadas entre las distintas estaciones.

Ello se logró con un conjunto de modelos individuales (puntuales) con sorteos aleatorios temporalmente independientes pero espacialmente correlacionados, mediante una simulación simultánea de secuencias de tiempo en múltiples puntos.

CAPÍTULO 7

APLICACIÓN AL MODELO HIDROLÓGICO

7. Aplicación al modelo hidrológico

La variabilidad temporal y espacial de la precipitación sobre una cuenca influye en la forma y duración de su hidrograma de salida, por lo que una buena caracterización de la lluvia en el espacio y tiempo conlleva a una mejora en los resultados de la modelación hidrológica y de la gestión del agua en última instancia.

En este sentido, en el presente capítulo se evalúa la habilidad del generador estocástico de precipitación diaria para predecir, a partir de acumulados mensuales y un modelo hidrológico, los caudales mensuales en una cuenca. El interés de basarse en un generador de tiempo de paso diario radica en su utilidad para otras aplicaciones incluyendo, eventualmente, modelos hidrológicos de paso diario. Surge entonces el desafío de representar correctamente los acumulados mensuales y, en el caso de cuencas de cierta extensión, la correlación espacial entre pluviómetros.

7.1 SELECCIÓN DE LA CUENCA DE ESTUDIO

Se seleccionó para el estudio una cuenca “grande”, comprendida en su totalidad en Uruguay. Esta es la cuenca del río Yí, afluente del Río Negro, con una extensión superficial de 13.700 km², localizada en los departamentos de Durazno, Flores y Florida.

Para la misma se dispone de registros diarios de precipitación en cuatro estaciones meteorológicas del INUMET durante el período 1981-2009: Treinta y Tres, Durazno, Trinidad y Florida. Será entonces necesario emplear generadores de clima multipunto, que consideren también las correlaciones espaciales entre los distintos puntos geográficos.

En la Figura 7-1 se presenta la delimitación de la cuenca de estudio y la distribución espacial de las estaciones disponibles, junto con el área de influencia de cada estación según el método de Thiessen (Tabla 7-1).



Figura 7-1: Delimitación de la cuenca de estudio, distribución espacial de las estaciones disponibles y polígonos de Thiessen asociados.

Tabla 7-1: Relación de áreas por estación según el método de Thiessen.

Estación	Área de influencia
Treinta y Tres	9%
Durazno	52%
Trinidad	15%
Florida	23%

7.2 METODOLOGÍA

7.2.1 Generación de series sintéticas de precipitación diaria

Para la cuenca del Yí, considerando su extensión, es necesario emplear generadores de clima multipunto que preserven las correlaciones espaciales entre las distintas estaciones. Por lo tanto, se empleó el generador multipunto Markov+Gamma desarrollado previamente en el capítulo 6.

Para la generación de las series sintéticas de precipitación diaria se realizaron tres simulaciones, que difieren en las matrices de correlaciones de ocurrencia $[\Omega]$ y montos de precipitación $[Z]$ entre las estaciones de la cuenca:

- **Sim1:** se consideró que no existe correlación espacial entre los distintos puntos geográficos (suertes independientes).
- **Sim2:** se consideró que la correlación entre las estaciones es máxima (suertes idénticas).
- **Sim3:** se calcularon las correlaciones para cada semestre, Abril-Set. (temporada fría) y Oct.-Marzo (temporada cálida), según la metodología explicada en el capítulo 6 (suertes correlacionadas).

En cada caso se simuló una serie de 1000 años de longitud.

A modo de ejemplo, la Figura 7-2 muestra la relación entre las correlaciones $\omega(k, l)$ y $\xi(k, l)$ para las estaciones Durazno y Trinidad (ubicadas a 50 km de distancia entre sí), calculada considerando las probabilidades de transición diarias de cada estación durante el semestre Abril-Set. Se observa que la curva resultante pasa por el origen, ya que variables independientes de forzamiento producirán series sintéticas independientes, y se eleva a un máximo de $\xi_{max}(k, l) = 0,950$ cuando las cadenas de Markov para los dos sitios son forzados con números aleatorios idénticos. Para estas dos estaciones, en el semestre Abril-Set, la correlación observada $\xi^0(k, l)$ es de 0,745 y los modelos de Markov reproducen esta correlación cuando son forzados por un ruido bivariado gaussiano estándar de $\omega(k, l) = 0,951$.




Figura 7-2: Ilustración de la relación entre las correlaciones $\omega(k, l)$ y $\xi(k, l)$ para el semestre Abril-Setiembre (temporada fría) entre las estaciones Durazno y Trinidad.

Una vez generadas las series sintéticas para cada estación y para cada simulación, se calculó la precipitación media en la cuenca mediante el método de Thiessen.

7.2.2 Simulación del proceso precipitación-escorrentía

La simulación del proceso precipitación-escorrentía en cada cuenca se realizó mediante el modelo de Temez de paso mensual (Temez, 1977), el cual se encuentra ampliamente difundido en Uruguay (IMFIA, 2002; MVOTMA, 2011; Crisci, 2012).

Este modelo reproduce el ciclo hidrológico de manera continua en el tiempo de una manera simple y conceptual, considerando ecuaciones con sentido físico. Es un modelo de balance hídrico concentrado y de cuatro parámetros: α , I_{max} , CP_0 y $H_{max} = C_{AD} * AD$ donde AD es el agua disponible en el suelo utilizable por el cultivo y C_{AD} un coeficiente que se ajusta en la calibración.

En este caso, los valores de los parámetros se consideraron iguales a los obtenidos en la calibración realizada a nivel regional a partir de los datos de escorrentía mensual registrados en doce subcuencas aforadas de Uruguay (MVOTMA, 2011). Dichos valores se presentan en la tabla siguiente.

Tabla 7-2: Parámetros del modelo de Temez calibrados para Uruguay.

Parámetro	Descripción	Valor
α	Coeficiente de descarga del almacenamiento subterráneo	0,0775 1/día
I_{max}	Capacidad máxima de infiltración	386 mm
CP_0	Coeficiente adimensionado para calcular la abstracción inicial de lluvia	0,30
H_{max}	Capacidad máxima de retención del agua en la capa superior del suelo	0,916*AD

Las variables de entrada al modelo y la forma en que fueron estimadas se presentan a continuación.

- **Precipitación**

Las series de precipitación media mensual en la cuenca fueron determinadas a través del método de Thiessen a partir de los datos registrados en las estaciones y a partir de las series sintéticas generadas con cada simulación. En todos los casos se acumuló mensualmente a partir de las series diarias.

A los escorrentías obtenidos a partir de las series observadas se les llamó "Obs".

- **Área de la cuenca**

El área de la cuenca fue determinada a partir de las curvas de nivel cada 10 m de las cartas topográficas del Servicio Geográfico Militar (SGM), escala 1:50.000, utilizando un SIG.

- **Evapotranspiración potencial (ETP)**

Dado que no se dispone de registros de ETP en la cuenca del Yí, se empleó el mapa de isolíneas de ETP media anual mensual extraído del “Manual de Diseño y Construcción de Pequeñas Presas” (MVOTMA, 2011).

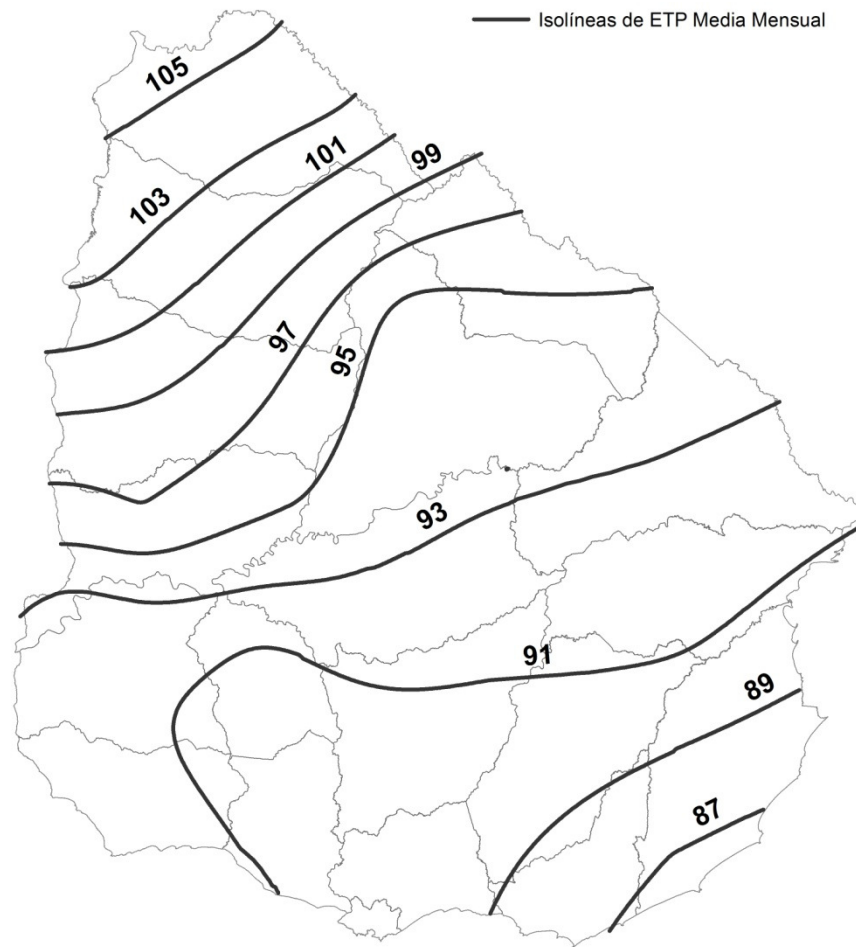


Figura 7-3: Mapa de isolíneas de ETP media mensual (Fuente: MVOTMA, 2011).

Luego, para transformar dicho valor medio mensual en un ciclo medio anual se emplearon los coeficientes de distribución del ciclo medio anual calibrados para el Uruguay, también extraídos de dicho Manual.

Tabla 7-3: Coeficientes de variación mensual de la ETP

Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
1,88	1,56	1,37	0,88	0,58	0,36	0,37	0,47	0,61	0,94	1,25	1,72

En la Figura 7-4 se presenta el ciclo medio anual de ETP obtenido para la cuenca del Yí.




Figura 7-4: Ciclo medio anual de evapotranspiración potencial.

- **Agua disponible del suelo**

El valor medio de agua disponible en la cuenca fue calculado a través de una ponderación por área ocupada por cada unidad de suelo dentro de la misma, de acuerdo a la información del Compendio Actualizado de Información de Suelos del Uruguay escala 1:1.000.000 (MGAP, RENARE), resultando un valor de 96 mm.

7.3 RESULTADOS

Para evaluar la habilidad del generador multipunto para predecir precipitación y -modelación hidrológica mediante- escurrimientos, se compararon determinados estadísticos de la serie observada (en lo que refiere a la precipitación, ya que no se trabajó con datos observados de caudal) con los de las series simuladas y se construyeron una serie de gráficos comparativos.

Además, para determinar la bondad del ajuste entre las distribuciones de las series simuladas y las observadas, se aplicó el test no paramétrico de Kolmogorov-Smirnov (K-S) para dos muestras independientes.

A continuación se presentan los resultados obtenidos.

En primer lugar, en la Figura 7-5 se presentan las matrices de correlaciones de ocurrencia $[\Omega]$ y montos de precipitación $[Z]$ consideradas para cada simulación (Sim1: suertes independientes, Sim2: suertes idénticas, Sim3: suertes correlacionadas tal que las correlaciones espaciales de las series sintéticas reproducen las de las observaciones). La entrada i, j corresponde

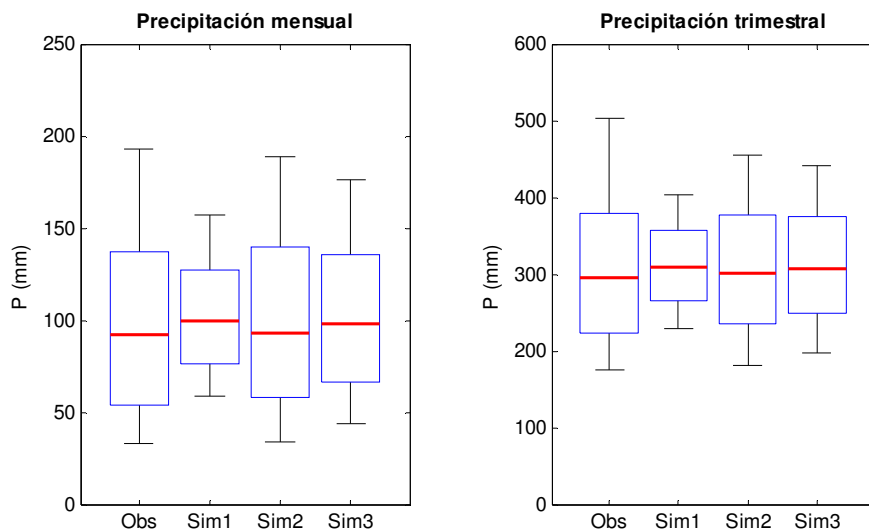
a la correlación entre las estaciones i y j , siendo 1: Treinta y Tres, 2: Durazno, 3: Trinidad y 4: Florida.

$$\begin{aligned}
 [\Omega]_{Sim1} = [Z]_{Sim1} &= \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} & [\Omega]_{Sim2} = [Z]_{Sim2} &= \begin{pmatrix} 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 \end{pmatrix} \\
 [\Omega]_{Sim3}^{Abr-Set} &= \begin{pmatrix} 1 & 0,900 & 0,841 & 0,830 \\ 0,900 & 1 & 0,951 & 0,896 \\ 0,841 & 0,951 & 1 & 0,916 \\ 0,830 & 0,896 & 0,916 & 1 \end{pmatrix} & [Z]_{Sim3}^{Abr-Set} &= \begin{pmatrix} 1 & 0,561 & 0,475 & 0,411 \\ 0,561 & 1 & 0,785 & 0,652 \\ 0,475 & 0,785 & 1 & 0,745 \\ 0,411 & 0,652 & 0,745 & 1 \end{pmatrix} \\
 [\Omega]_{Sim3}^{Oct-Mar} &= \begin{pmatrix} 1 & 0,830 & 0,775 & 0,771 \\ 0,830 & 1 & 0,944 & 0,868 \\ 0,775 & 0,944 & 1 & 0,871 \\ 0,771 & 0,868 & 0,871 & 1 \end{pmatrix} & [Z]_{Sim3}^{Oct-Mar} &= \begin{pmatrix} 1 & 0,502 & 0,383 & 0,444 \\ 0,502 & 1 & 0,727 & 0,539 \\ 0,383 & 0,727 & 1 & 0,617 \\ 0,444 & 0,539 & 0,617 & 1 \end{pmatrix}
 \end{aligned}$$

Figura 7-5: Matrices de correlaciones entre estaciones para cada simulación (Sim1: Suertes independientes, Sim2: Suertes idénticas, Sim3: Suertes correlacionadas).

Se observa que en general, tal como era de esperar, las correlaciones entre las distintas estaciones son menores en la temporada cálida (Oct-Marzo), cuando son más frecuentes los sistemas precipitantes de origen convectivo de menor escala espacial.

En la Figura 7-6 se presentan los diagramas de caja de acumulados mensuales y trimestrales de precipitación para la serie observada y las series simuladas con el generador multipunto Markov+Gamma, a la vez que los escurrimientos asociados simulados con Temez. Se incluyen los percentiles 25, 50, 75 (cajas) y 10 y 90 (bigotes).






Figura 7-6: Distribución de totales mensuales y trimestrales de precipitación para la serie observada y las series simuladas y distribución asociada de escurrimiento según Temez, para la cuenca del río Yí. Se incluyen los percentiles 25, 50, 75 (cajas) y 10 y 90 (bigotes).

Las precipitaciones observadas presentan mayor dispersión (mayor intervalo entre deciles extremos) que las simuladas, sobre todo a nivel trimestral, lo cual se refleja en los escurrimientos pero atenuado debido a la no-linealidad de la relación precipitación-caudal. La ventaja de incorporar la correlación espacial entre estaciones es notoria. Sin embargo, la simulación con suertes idénticas parece presentar un desempeño superior al de suertes correlacionadas, lo cual puede deberse a la compensación con una correlación espacial exagerada de la varianza temporal multimensual que no rescata el modelo.

Finalmente, se empleó el test K-S para contrastar la hipótesis nula de que dos muestras independientes de tamaños n y m (en este caso, serie observada y simulada) proceden de una misma distribución (sin especificar la misma). Para ello se comparan las funciones de distribución acumulada de ambas muestras, $F_n(x_{obs})$ y $F_m(x_{sim})$, y se calcula el estadístico del test según:

$$D_s = \max_x |F_n(x_{obs}) - F_m(x_{sim})|$$

el cual se interpreta como la mayor diferencia (en valor absoluto) entre las distribuciones empíricas acumuladas de n observaciones de x_{obs} y m observaciones de x_{sim} .

La hipótesis nula, que afirma que las distribuciones poblacionales de las dos muestras son iguales, se rechaza al nivel de significación α cuando (Wilks, 2006):

$$D_s > \left[-\frac{1}{2} \left(\frac{1}{n} + \frac{1}{m} \right) \ln \left(\frac{1}{\alpha} \right) \right]^{1/2}$$

Si la hipótesis nula es cierta, es de esperar que dicha diferencia sea pequeña, y en ese caso se dice que la serie simulada reproduce la distribución observada.

En la Tabla 7-4 se presenta el valor del estadístico obtenido para cada una de las series simuladas de acumulados mensuales y trimestrales de precipitación y escurrimiento en comparación con las series observadas. En color rojo (verde) se indican los casos en los que se rechaza (no se rechaza) la hipótesis nula.

Tabla 7-4: Distancia máxima entre las distribuciones empíricas acumuladas (estadístico del test K-S) de las series observadas y las series simuladas (Sim1: Suertes independientes, Sim2: Suertes idénticas, Sim3: Suertes correlacionadas).

Distancia máxima entre distribuciones acumuladas				
Variable	Umbral ($\alpha = 0,01$)	Sim1	Sim2	Sim3
Precipitación mensual	0,089	0,194	0,039	0,096
Precipitación trimestral	0,153	0,195	0,067	0,106
Volumen escurrido mensual	0,089	0,096	0,028	0,052
Volumen escurrido trimestral	0,153	0,097	0,051	0,055

De la tabla anterior se desprende que según el test de K-S, adoptando un nivel de confianza del 99%, la simulación con suertes independientes no logra reproducir la distribución observada de precipitación (mensual y trimestral) ni de escurrimientos mensuales, aunque sí la del volumen escurrido a nivel trimestral. En cambio, las simulaciones con suertes idénticas y correlacionadas sí logran reproducir las distribuciones observadas, excepto la de precipitación mensual en el caso de suertes correlacionadas.

7.4 CONCLUSIONES

Se evaluó la habilidad de un generador estocástico de precipitación diaria para representar las propiedades estadísticas de acumulados mensuales y trimestrales de precipitación y -modelación hidrológica mediante- de escurrimiento para una cuenca de Uruguay, la cuenca del río Yí, que requiere considerar también las correlaciones espaciales entre los distintos puntos geográficos.

Para ello se empleó el generador multipunto Markov+Gamma con parámetros variables a lo largo del año, desarrollado previamente en el capítulo 6, de forma tal que las correlaciones espaciales de las series sintéticas resultantes reproducen las de las observaciones.

Se llegó a que las series simuladas de esta forma reproducen de manera satisfactoria las distribuciones observadas tanto de precipitación como escurrimiento, siendo indiscutible la ventaja de incorporar la correlación espacial entre estaciones.

CAPÍTULO 8

CONCLUSIONES

8. Conclusiones

En este trabajo de tesis, luego de una extensa revisión bibliográfica, se formularon y evaluaron distintos modelos estocásticos para la simulación de la precipitación diaria en un punto geográfico, con el propósito de seleccionar el modelo más adecuado para Uruguay, al cual luego incorporarle sesgos climáticos y la correlación espacial entre las distintas estaciones.

En primer lugar se implementó un modelo de cuatro parámetros, denominado “Markov+Gamma”, que emplea una cadena de Markov de primer orden para simular la ocurrencia de precipitación diaria (a partir de las probabilidades de que llueva condicionales a que llovió o no llovió el día anterior), y la distribución gamma de dos parámetros (α y β , parámetros de forma y escala respectivamente) para simular la cantidad de precipitación en los días lluviosos. Este modelo fue implementado en dos modalidades: i) asumiendo que los parámetros son estacionarios a lo largo del año y, ii) incorporando el ciclo medio anual de los parámetros, para lo cual para cada día del año se consideró una ventana móvil centrada de +/- 30 días donde se entrenaron los valores de los parámetros que se asignan a dicho día. En ambos casos los parámetros del modelo fueron estimados mediante el método de máxima verosimilitud.

Se formuló luego un segundo modelo denominado “Markov+Exp.Mixta”, de cinco parámetros, que difiere en el método para simular la cantidad de precipitación de los días lluviosos, en el cual la misma se sorteaba a partir de una distribución exponencial mixta de tres parámetros (α : parámetro de ponderación, β_1 y β_2 : parámetros de las distribuciones exponenciales). Este modelo fue implementado considerando parámetros variables a lo largo del año, con procedimiento análogo al explicado anteriormente.

Los modelos desarrollados fueron entrenados en 22 estaciones meteorológicas de Uruguay, en las cuales se disponía de datos diarios de precipitación en el período 1981-2009 (período con mayor cantidad de datos simultáneos). Si bien los montos de precipitación en las estaciones pluviométricas son muy semejantes a los de las estaciones meteorológicas, presentan diferencias sutiles (menor registro de días con muy poca lluvia) que afectan a los parámetros del generador de tiempo por lo que no es conveniente incluirlas.

Una vez estimados los parámetros para cada modelo y punto geográfico, se simularon 100 series de 10.585 días de longitud, equivalentes al largo de las series históricas disponibles.

Para evaluar la habilidad del ensemble generado en cada caso se consideraron estadísticos enfocados tanto en los días de lluvia como en los montos de precipitación (frecuencia de lluvia, probabilidades de que llueva condicionales a que llovió o no llovió el día anterior, longitud de rachas secas, precipitación diaria y acumulados mensuales, trimestrales y anuales, recurrencia de eventos lluviosos, etc.), a partir de los cuales se realizaron diversos análisis apuntando a la reproducción del ciclo y media anual, así como a la variabilidad interanual y a la distribución de extremos.

En general se verifica que las series simuladas reproducen de manera satisfactoria los estadísticos seleccionados de las series observadas, siendo indiscutible la ventaja de incorporar el ciclo medio anual de los parámetros. El peor desempeño lo presentan en lo que respecta a la variabilidad en escalas multimensual e interanual (ambos modelos producen sobredispersión) y a los valores extremos de exceso y déficit hídrico (en algunos casos los modelos subestiman los valores máximos observados). Como es de esperar, cuanto más sensible es el estadístico a eventos extremos muy esporádicos, más difícil es entrenar los modelos para que dicho estadístico sea reproducido adecuadamente.

Respecto a la evaluación comparativa de los dos modelos desarrollados, de los resultados obtenidos para Uruguay se desprende que si bien el generador Markov+Exp.Mixta tiene un desempeño marginalmente superior que el Markov+Gamma (sobre todo en lo que refiere a la variabilidad interanual), no se justifica el uso de un modelo menos parsimonioso. Esta conclusión resulta interesante ya que, según numerosos trabajos anteriores desarrollados fundamentalmente para Estados Unidos, la distribución exponencial mixta tiene un desempeño sustancialmente superior que la distribución gamma. Sin embargo, dado el relativamente estrecho espectro de regímenes climáticos en Uruguay, se

llegó a que no se justifica el uso de distribuciones mixtas para simular la intensidad de precipitación diaria.

Por lo tanto, se continuó trabajando con el modelo Markov+Gamma con parámetros variables a lo largo del año.

Luego, se procedió a la incorporación de sesgos climáticos al generador de tiempo desarrollado, buscando que dicha herramienta sea útil para la aplicación en sistemas expuestos a riesgo climático.

Para ello, en primer lugar, se realizó una caracterización de la señal de ENOS en estadísticos de precipitación a partir de datos diarios en Uruguay. El análisis consistió en estratificar las series de datos en cuartiles según el índice N3.4 en el trimestre NDE y calcular, para cada cuartil, el ciclo medio anual para el año climatológico (Set.-Ago.) de diversos estadísticos considerando una ventana móvil centrada de +/- 30 días. Al igual que para la evaluación de los generadores de tiempo desarrollados, se consideraron estadísticos enfocados tanto en los días de lluvia como en los montos de precipitación. Se obtuvieron varios resultados novedosos: la identificación de los períodos de señal independizados de los meses calendario, la separación del sesgo en montos y en frecuencia de lluvia y las diferencias regionales en ambos sesgos. En el caso de los montos de precipitación, tanto para los eventos El Niño como La Niña, la señal significativa se limita casi exclusivamente a la primavera e inicio del verano, presentando un gradiente de sureste a noroeste. En cambio, para la frecuencia de días de lluvia, también se identificaron períodos significativos de menos días de lluvia de lo habitual para los eventos La Niña durante el período Marzo-Julio en varios casos. Además, otra diferencia es que las variaciones regionales de la señal de ENOS en la frecuencia de lluvia son menos notorias que cuando se consideran los montos, siendo la señal más intensa en Melo (región este) y no en Artigas (región noroeste).

Se propuso luego una metodología para la incorporación de sesgos climáticos al generador de tiempo Markov+Gamma con parámetros variables a lo largo del año, mediante una variable de condicionamiento que permite remuestrear selectivamente los datos históricos de modo de producir secuencias sintéticas consistentes con un escenario determinado. En este caso, como variable de condicionamiento se emplearon las anomalías del índice N3.4 promediadas en el trimestre NDE para años no calendario que van de setiembre a agosto.

Los resultados obtenidos muestran que el procedimiento desarrollado logra capturar satisfactoriamente la señal de ENOS, siendo clara su influencia sobre el régimen de precipitación, sobre todo durante las fases extremas, El Niño y la Niña. Esto resulta muy interesante ya que plantea la

posibilidad de prever sesgos en la distribución esperada de la lluvia empleando como predictor el ENOS, predictor climático más importante de la precipitación en Uruguay, sobre todo considerando la existencia de numerosos modelos que pronostican exitosamente el índice N3.4 hasta con un año de antelación.

Algunas aplicaciones requieren considerar la precipitación acumulada sobre un área de cierta extensión, lo cual exige considerar también la correlación espacial entre pluviómetros. Surge entonces el desafío de implementar un generador de clima multipunto, que preserve las correlaciones espaciales (simultáneas) observadas entre las distintas estaciones.

Para ello, al modelo Markov+Gamma puntual se lo modificó de forma tal de generar un conjunto de modelos individuales con sorteos aleatorios temporalmente independientes pero espacialmente correlacionados, a través de la simulación simultánea de secuencias de tiempo en múltiples puntos empleando una distribución normal multivariada. Se realizaron análisis diferenciales para el semestre Abril-Set. (temporada fría) y Oct.-Marzo (temporada cálida), considerando que los mecanismos de lluvia son distintos y por tanto la correlación espacial de la precipitación potencialmente también.

Finalmente, se aplicó el generador de tiempo para el cálculo del escurrimiento mensual mediante el modelo de precipitación-escurrimiento de Temez, el cual se encuentra ampliamente difundido en Uruguay. Para el estudio se seleccionó la cuenca del río Yí, afluente del Río Negro, con una extensión superficial de 13.700 km² comprendida en su totalidad en Uruguay, que requiere considerar también las correlaciones espaciales entre los distintos puntos geográficos. Se evaluó la habilidad del generador multipunto Markov+Gamma (desarrollado previamente) para representar las propiedades estadísticas de acumulados mensuales y trimestrales de precipitación y -modelación hidrológica mediante- de escurrimiento en la cuenca. Se llegó a que las series simuladas de esta forma reproducen de manera satisfactoria las distribuciones observadas tanto de precipitación como escurrimiento, siendo notoria la ventaja de incorporar la correlación espacial entre estaciones.

De esta manera, como resultado de este trabajo de tesis se obtuvo una herramienta de modelación estocástica de precipitación diaria en Uruguay de utilidad en diversos sectores tales como la gestión de recursos hídricos y productivos, capaz de reproducir el clima medio de la variable de interés (incluyendo la co-variabilidad espacial) e incorporar sesgos en presencia de forzantes climáticos como ENOS.

CAPÍTULO 9

FUTURAS LÍNEAS DE INVESTIGACIÓN

9. Futuras líneas de investigación

A continuación se enumeran algunas de las posibles líneas de investigación a desarrollar en el futuro:

- Generalización de la metodología propuesta para la incorporación de sesgos climáticos al modelo desarrollado, de modo que permita mayor flexibilidad en la construcción de series sintéticas de precipitación asociadas a predicción climática estacional en sus diversas metodologías (numérica, estadística y combinada) y -eventualmente- también para escenarios climáticos en horizontes de tiempo mayores.
- Adaptación del modelo multipunto de manera de considerar la correlación desfasada (por ejemplo entre un día y el siguiente) entre las series a medida que aumenta la distancia entre estaciones, de modo de capturar estadísticamente la evolución temporal y espacial del sistema precipitante (Joyce et al., 2004).
- Incorporación de variabilidad en los parámetros del modelo alrededor de su valor esperado, de modo de aumentar la variabilidad temporal de las series sintéticas de precipitación diaria (Jones y Thornton, 1997). Esto también podría contribuir a mejorar la reproducción de los valores extremos de las series observadas.
- Incorporación de otras variables meteorológicas (radiación solar, evaporación, temperatura mínima y máxima, etc.) al generador de tiempo desarrollado, incluyendo la co-variabilidad espacial y entre variables (Richardson, 1981; Wilks, 1999b). El elemento restrictivo para esta línea de trabajo es la conformación de bases de datos observadas de calidad, frecuencia, cobertura y extensión adecuada.

- Generación de series sintéticas de precipitación diaria en puntos y áreas donde no se dispone de registros históricos, mediante la interpolación de parámetros entrenados en estaciones próximas y/o integración espacial de montos simulados por el generador de tiempo (Wilks, 2008; Wilks, 2009; Camberlin et al., 2014).

CAPÍTULO 10

REFERENCIAS BIBLIOGRÁFICAS

10. Referencias bibliográficas

- Aceituno P. (1992). El Niño, the Southern Oscillation, and ENSO: Confusing names for a complex ocean–atmosphere interaction. *Bull. Amer. Meteor. Soc.*, **73**, 483-485.
- Ailliot P., Allard D., Monbet V., Naveau P. (2014). Stochastic weather generators: an overview of weather type models (Preprint). http://perso.univ-rennes1.fr/valerie.monbet/doc/papiers_pdf/SWGEN_review.pdf
- Akaike H. (1974). A new look at statistical model identification. *IEEE Trans. Auto. Control*, **AC 19**, 716-722.
- Aksoy H. (2000). Use of gamma distribution in hydrological analysis. *Turkish J. Eng. Env. Sci.*, **24**, 419-428.
- Amiel J., Renom M., Scavino M (2012). *Estudio de diferentes metodologías estadísticas para el control de calidad de la base de datos diarios de precipitación en Uruguay*. Informe de pasantía en la Unidad de Ciencias de la Atmósfera, Facultad de Ciencias, UdelaR.
- Apipattanavis S., Podesta G., Rajagopalan B., Katz R. (2007). A semiparametric multivariate and multisite weather generator. *Water Resour. Res.*, **43**, 1-19.
- Baethgen W.E., Meinke H., Giménez A. (2004). Adaptation of agricultural production systems to climate variability and climate change: lessons learned and proposed research approach. *Insights and Tools for Adaptation: Learning from Climate Variability*, NOAA-OGP, Washington, D.C.
- Baigorria G.A., James W.J. (2010). GiST: A stochastic model for generating spatially and temporally correlated daily rainfall data. *J. Climate*, **23**, 5990-6008.

- Beersma J.J., Buishand T.A. (2003). Multi-site simulation of daily precipitation and temperature conditional on the atmospheric circulation. *Climate Res.*, **25**, 121-133.
- Besson L. (1924). On the probability of rain. *Monthly Weather Review*, **52**, 308.
- Brissette F.P., Khalili M., Leconte R. (2007). Efficient stochastic generation of multi-site synthetic precipitation data. *J. Hydrol.*, **345**, 121-133.
- Buishand T.A. (1977). *Stochastic modelling daily rainfall sequences*. Meded. Landbouwhogeschool, Wageningen, **77**, 211pp.
- Burton A., Kilsby C.G., Fowler H.J., Cowpertwait P.S.P., O'Connell P.E. (2008). RainSim: A spatial-temporal stochastic rainfall modelling system. *Environ. Modell. Software*, **23**, 1356-1369.
- Camberlin P., Gitau W., Oettli P., Ogallo L., Bois B. (2014). Spatial interpolation of daily rainfall stochastic generation parameters over East Africa. *Clim Res*, **59**, 39-60.
- Campbell G.S. (1990). CLIMGEN, A program that generates weather data (precipitation, maximum and minimum temperature). Biological Systems Engineering Dept., Washington State University, Pullman, Washington, USA.
- Cannon A. (2008). Probabilistic multisite precipitation downscaling by an expanded Bernoulli-Gamma density network. *J. Hydrometeor.*, **9**, 1284-1300.
- Cazes-Boezio G., Robertson A., Mechoso R. (2003). Seasonal Dependence of ENSO Teleconnections over South America and Relationships with Precipitation in Uruguay. *Journal of Climate*, **16**, 1159-1176.
- Chin E.H. (1977). Modelling daily precipitation occurrence process with Markov chain. *Water Resour. Res.*, **13**, 949-956.
- Coe R., Stern R.D. (1982). Fitting models to daily rainfall. *J. Appl. Meteorol.*, **21**, 1024-1031.
- Crisci M. (2012). Modelación de los recursos hídricos y sus principales usos en la cuenca de aporte a Rincón del Bonete. Evaluación económica comparativa. Tesis de Maestría en Ingeniería - Mecánica de los fluidos aplicada. Facultad de Ingeniería, Universidad de la República, Montevideo, Uruguay.
- Detzel D.H.M., Mine M.R.M. (2011). Generation of daily synthetic precipitation series: Analyses and application in La Plata Basin. *The Open Hydrology Journal*, **5**, 69-77.

- Díaz A.F., Studzinski C.D., Mechoso C.R. (1998). Relationships between precipitation anomalies in Uruguay and southern Brazil and sea surface temperature in the Pacific and Atlantic Oceans. *J. Climate*, **11**, 251–271.
- Fowler H.J., Kilsby C. G., O’Connell P. E., Burton A. (2005). A weather-type conditioned multi-site stochastic rainfall model for the generation of scenarios of climatic variability and change. *J. Hydrol.*, **308**, 50-66.
- Gabriel K.R., Neumann J. (1962). A Markov chain model for daily rainfall occurrence at Tel Aviv. *Quarterly Journal of the Royal Meteorological Society*, **88**, 90-95.
- Gregory J.M., Wigley T.M.L., Jones P.D. (1993). Application of Markov models to area-average daily precipitation series and interannual variability in seasonal totals. *Climate Dynamics*, **8**, 299-310.
- Grondona M., Podesta G., Bidegain M., Marino M., H. Hordij (2000). Stochastic precipitation generator conditioned on ENSO phase: A case study in southeastern South America”. *Journal of Climate*, **13**, 2973-2986.
- Hanson C.L., Cumming K.A., Woolhiser D.A., Richardson C.W. (1994). Microcomputer program for daily weather simulation in the contiguous United States. *Agricultural Research Service*, **114**, 38 pp.
- Hussain A. (2008). *Stochastic modeling of rainfall processes: a Markov chain – mixed exponential model for rainfalls in different climatic conditions*. Master thesis of Engineering. Department of Civil Engineering and Applied Mechanics, McGill University, Montreal.
- IMFIA (2002). Directivas de diseño hidrológico-hidráulico de pequeñas represas. Convenio IMFIA-DNH, Uruguay.
- INIA (2011). Caracterización agroclimática del Uruguay, 1980-2009. Serie Técnica N° 193, INIA, Uruguay.
- Jones P.G., Thornton P.K. (1997). Spatial and temporal variability of rainfall related to a third-order Markov model. *Agricultural and Forest Meteorology*, **86**, 127-138.
- Joyce R.J., Janowiak J.E., Arkin P.A., Xie P. (2004). CMORPH: A method that produces global precipitation estimates from passive microwave and infrared data at high spatial and temporal resolution. *J. Hydrometeor.*, **5**, 487-503.
- Katz R.W. (1977a). Precipitation as a chain-dependent process. *Journal of Applied Meteorology*, **16**, 671-76.

- Katz R.W. (1977b). An application of chain-dependent processes to meteorology. *Journal of Applied Probability*, **14**, 598-603.
- Katz R.W., Parlange M.B. (1998). Overdispersion phenomenon in stochastic modeling of precipitation. *Journal of Climate*, **11**, 591-601.
- Khalili M., Leconte R., Brissette F. (2007). Stochastic multisite generation of daily precipitation data using spatial autocorrelation. *J. Hydrometeor.*, **8**, 396-412.
- Leander R., Buishand T.A. (2009). A daily weather generator based on a two-stage resampling algorithm. *J. Hydrol.*, **374**, 185-195.
- Maraun D. et al. (2010): Precipitation downscaling under climate change: Recent developments to bridge the gap between dynamical models and the end user. *Rev. Geophys.*, **48**, RG3003.
- Mehrotra R., Srikanthan R., Sharma A. (2006). A comparison of three stochastic multi-site precipitation occurrence generators. *J. Hydrol.*, **331**, 280-292.
- MVOTMA (2011). Manual de Diseño y Construcción de Pequeñas Presas. Ministerio de Vivienda, Ordenamiento Territorial y Medio Ambiente, Uruguay.
- Newnham E.V. (1916). The persistence of wet and dry weather. *Quarterly Journal of the Royal Meteorological Society*, **42**, 153-62.
- Nicks A.D., Gander G.A. (1994). *CLIGEN: A weather generator for climate inputs to water resource and other models*. Proceedings of the 5th International Conference on Computers in Agriculture. American Society of Agricultural Engineers, St. Joseph, Michigan, pp. 3-94.
- Palutikof J.P., Goodess C.M., Watkins S.J., Holt T. (2002). Generating rainfall and temperature scenarios at multiple sites: Examples from the Mediterranean. *J. Climate*, **15**, 3529-3548.
- Pisciottano G., Diaz A., Cazes G., Mechoso C.R. (1994). El Niño-Southern Oscillation Impact on Rainfall in Uruguay. *J. Climate*, **7**, 1286-1302.
- Qian B., Corte-Real J., Xu H. (2002). Multisite stochastic weather models for impact studies. *Int. J. Climatol.*, **22**, 1377-1397.
- Rajagopalan B., Lall U., Tarboton D.G. (1996). A nonhomogeneous Markov model for daily precipitation simulation. *ASCE, Journal of Hydrologic Engineering*, **1**(1), 33-40.
- Rascko P., Szeidl L., Semenov M. (1991). A Serial Approach to Local Stochastic Weather Models. *Ecological Modelling*, **57**: 27-41.

- Richardson C.W. (1981). Stochastic simulation of daily precipitation, temperature and solar radiation. *Water Resources Research*, **17**, 182-190.
- Richardson C.W., Wright D.A. (1984). *WGEN: A model for generating daily weather variables*. US Department of Agriculture, Agricultural Research Service, ARS-8, 83pp.
- Roldan J., Woolhiser D.A. (1982). Stochastic daily precipitation models, 1. A comparison of occurrence processes. *Water Resour. Res.*, **18**, 1451-1459.
- Ropelewski C.F., Halpert M.S. (1987). Global and regional scale precipitation patterns associated with the El Niño–Southern Oscillation. *Mon. Wea. Rev.*, **115**, 1606-1626.
- Ropelewski C.F., Halpert M.S. (1989). Precipitation patterns associated with the high index phase of Southern Oscillation. *J. Climate*, **2**, 268-284.
- Schwarz G. (1978). Estimating the dimension of a model. *Ann. Stat.*, **6**, 461-464.
- Semenov M.A., Barrow E.M. (1997). Use of a stochastic weather generator in the development of climate change scenarios. *Climatic Change*, **35**: 397-414.
- Srikanthan R., McMahon T.A. (2001). Stochastic generation of annual, monthly and daily climate data: a review. *Hydrol. Earth Syst. Sci.*, **5**, 653-670.
- Srikanthan R., Pegram G.G.S. (2009). A nested multisite daily rainfall stochastic generation model. *J. Hydrol.*, **371**, 142-153.
- Stern R.D., Coe R. (1984). A model fitting analysis of daily rainfall data. *J. Roy. Statist. Soc. A*, **147**, Part 1, 1-34.
- Temez J.R. (1977). Modelo matemático de transformación Precipitación–Aportación. *ASINEL*.
- Terra R., Pisciotto G. (1994). *Regionalización del Uruguay según el ciclo anual de precipitaciones mediante “Cluster Analysis”*. Instituto de Mecánica de los Fluidos e Ingeniería Ambiental, Universidad de la República, Montevideo, Uruguay.
- Todorovic P., Woolhiser D.A. (1975). A stochastic model of n-day precipitation. *Journal of Applied Meteorology*, **14**, 17-24.
- Trenberth K.E. (1997). The definition of El Niño. *Bull. Amer. Met. Soc.*, **78**, 2771-2777.

- Wilby R.L. (1994). Stochastic weather type simulation for regional climate change impact assessment. *Water Resources Research*, **30**, 3395-403.
- Wilby R.L., Tomlinson O.J., Dawson C.W. (2003). Multi-site simulation of precipitation by conditional resampling. *Climate Res.*, **23**, 183-194.
- Wilks D.S. (1992). Adapting stochastic weather generation algorithms for climate changes studies. *Clim Change*, **22**: 67-84.
- Wilks D.S. (1998). Multisite generalization of a daily stochastic precipitation generation model. *J Hydrol*, **210**: 178-191.
- Wilks D.S. (1999a). Interannual variability and extreme-value characteristics of several stochastic daily precipitation models. *Agric. For. Meteorol.*, **93**, 153-169.
- Wilks D.S. (1999b). Simultaneous stochastic simulation of daily precipitation, temperature and solar radiation at multiple sites in complex terrain, *Agric. For. Meteorol.*, **96**, 85-101.
- Wilks D. S. (2006): *Statistical Methods in the Atmospheric Sciences*. Second edition. International Geophysics Series.
- Wilks D.S. (2008). High-resolution spatial interpolation of weather generator parameters using local weighted regressions, *Agric. For. Meteorol.*, **148**, 111-120.
- Wilks D.S. (2009). A gridded multisite weather generator and synchronization to observed weather data, *Water Resour. Res.*, **45**, W10419.
- Wilks D.S. (2010). Use of stochastic weather generators for precipitation downscaling. *Wiley Interdisciplinary Reviews: Climate Change*, **1**(6): 898-907.
- Wilks D.S. (2012). Stochastic weather generators for climate-change downscaling, part ii: multivariable and spatially coherent multisite downscaling. *Wiley Interdisciplinary Reviews: Climate Change*, **3**(3): 267-278.
- Wilks D.S., Wilby R.L. (1999). The weather generation game: a review of stochastic weather models. *Progress in Physical Geography*, **23**, 329-357.
- Woolhiser D.A., Pegram G.G.S. (1979). Maximum likelihood estimation of Fourier coefficients to describe seasonal variations of parameters in stochastic daily precipitation models. *Journal of Applied Meteorology*, **18**, 34-42.

Woolhiser D.A., Roldan J. (1982). Stochastic daily precipitation models. 2. A comparison of distribution of amounts. *Water Resources Research*, **18**, 1461-68.