

UNIVERSIDAD NACIONAL DEL LITORAL



Modelación de Variables Hidroclimáticas de Superficie y Evolución de su Comportamiento en Eventos Extremos Secos

Leandro C. Sgroi

FICH

FACULTAD DE INGENIERIA

Y CIENCIAS HIDRICAS

INTEC

INSTITUTO DE DESARROLLO TECNOLOGICO

PARA LA INDUSTRIA QUIMICA

Tesis de Doctorado 2017



UNIVERSIDAD NACIONAL DEL LITORAL

Facultad de Ingeniería y Ciencias Hídricas

Instituto de Desarrollo Tecnológico para la Industria Química

**MODELACION DE VARIABLES
HIDROCLIMATICAS DE SUPERFICIE Y
EVOLUCIÓN DE SU COMPORTAMIENTO EN
EVENTOS EXTREMOS SECOS**

Leandro C. Sgroi

Tesis remitida al Comité Académico del Doctorado

como parte de los requisitos para la obtención

del grado de

DOCTOR EN INGENIERIA

Mención Recursos Hídricos

de la

UNIVERSIDAD NACIONAL DEL LITORAL

2017

Comisión de Posgrado, Facultad de Ingeniería y Ciencias Hídricas, Ciudad Universitaria, Paraje 'El Pozo',

S3000, Santa Fe, Argentina.

MODELACION DE VARIABLES HIDROCLIMATICAS DE SUPERFICIE Y EVOLUCIÓN DE SU COMPORTAMIENTO EN EVENTOS EXTREMOS SECOS

Leandro C. Sgroi

Lugar de Trabajo:

CEVARCAM - FICH - UNL
Centro de Estudios en Variabilidad y Cambio Climático
Facultad de Ingeniería y Ciencias Hídricas
Universidad Nacional del Litoral

Director de Tesis:

Norberto Oscar García Centro de Estudios en Variabilidad y Cambio Climático -
Facultad de Ingeniería y Ciencias Hídricas - Universidad
Nacional del Litoral

Co-director de Tesis:

Ernesto Hugo Berbery Earth System Science Interdisciplinary Center/Cooperative
Institute for Climate and Satellites-Maryland - University of
Maryland

Jurado Evaluador:

Facultad de Ingeniería y Ciencias Hídricas
UNIVERSIDAD NACIONAL DEL LITORAL

2017

MODELACION DE VARIABLES HIDROCLIMATICAS DE SUPERFICIE Y EVOLUCIÓN DE SU COMPORTAMIENTO EN EVENTOS EXTREMOS SECOS

Leandro C. Sgroi

Lugar de Trabajo:

CEVARCAM - FICH - UNL
Centro de Estudios en Variabilidad y Cambio Climático
Facultad de Ingeniería y Ciencias Hídricas
Universidad Nacional del Litoral

Director de Tesis:

Norberto Oscar García Centro de Estudios en Variabilidad y Cambio Climático -
Facultad de Ingeniería y Ciencias Hídricas - Universidad
Nacional del Litoral

Co-director de Tesis:

Ernesto Hugo Berbery Earth System Science Interdisciplinary Center/Cooperative
Institute for Climate and Satellites-Maryland - University of
Maryland

Jurado Evaluador:

Facultad de Ingeniería y Ciencias Hídricas
UNIVERSIDAD NACIONAL DEL LITORAL

2017

Dedicatoria

A Mi Familia, quienes en muchas ocasiones han creído y depositado su confianza en mí, más de lo que yo mismo lo hice.

Agradecimientos

Especialmente quiero agradecer al Centro de Estudios de Variabilidad y Cambio Climático (CEVARCAM), de la Facultad de Ingeniería y Ciencias Hídricas (FICH) perteneciente a la Universidad Nacional del Litoral (UNL), por ser el lugar donde trabajo y he desarrollado esta tesis, y por haberme brindado las disponibilidades necesarias. También quiero agradecer al proyecto PICT-2008/1576, y a los proyectos del Inter-American Institute for Global Change Research (IAI) proyectos CRN3035 y CRN3095, por el financiamiento de estudios y trabajos.

- A mi director Dr. Norberto García, por su confianza en mí para realizar esta tesis; de igual manera agradecer a mi co-director Dr. E. Hugo Berbery por su disponibilidad, celeridad para resolver problemas y motivación, y por sus consejos y sugerencias que en todo momento han sido muy provechosos para el desarrollo de la tesis.

- Al grupo de compañeros de CEVARCAM: Omar, Miguel, Carlos, Diego, Agustina y María del Valle, quienes han intercambiado consejos, experiencias y sugerencias conmigo en todo momento.

- A mi familia y amigos por el aguante.

Resumen

Las sequías son eventos extremos que producen mayores pérdidas económicas cuando afectan a una región en particular. Principalmente porque no hay sistemas de alerta que puedan anticipar con certeza el inicio de estos eventos, y cuando finalmente se detectan, estos ya se encuentran en un estado avanzado. Frente a esta situación, la motivación de este trabajo se enfoca en generar una herramienta que pueda detectar la ocurrencia de eventos extremos y monitorear su situación con cierta anticipación. De esta forma brindar información de calidad a los responsables de la toma de decisión para reducir los impactos de estos fenómenos en la sociedad.

Los objetivos que se plantean en esta tesis se encuentran desarrollados en los capítulos de la misma, y se los puede considerar en tres partes. Una primera que involucra la construcción de índices de monitoreo a través de una metodología no paramétrica que utiliza una función de probabilidad empírica para ajustar al comportamiento de la variable; esta metodología resulta aplicable tanto a la precipitación como al resto de las variables hidrológicas que se evalúan.

Una segunda parte que engloba dos objetivos, por un lado la implementación de un modelo hidrológico de superficie en la cuenca del Plata para simular campos de variables hidrológicas de difícil estimación. Por otro lado, esto ha permitido desarrollar una climatología de eventos extremos secos durante el período 1980-2010, a través de indicadores estandarizados de las variables de superficie simuladas, que se construyeron con la metodología no paramétrica.

Finalmente se determinó un sistema de que permite monitorear y predecir la ocurrencia de eventos secos en esta región de Sudamérica. El pronóstico se realizó forzando al modelo de superficie con variables pronosticadas a 9 meses. Se evaluó la habilidad de pronóstico de la metodología propuesta comparando para una fecha en particular situaciones pronosticadas con situaciones simuladas a tiempo casi real.

Abstract

Droughts are extreme events that produce greater economic losses when they affect a particular region. Mainly because there are no alert systems that can anticipate with certainty the beginning of these events, and when finally detected, is already in an advanced state. Faced with this situation, the motivation of this work focuses on generating a tool that can detect the occurrence of extreme events and monitor their situation with some anticipation. In this

way provide quality information to the people responsible for decision making to reduce the impacts of these phenomena on society.

The objectives presented in this thesis are developed in the chapters of the same, and can be considered in three parts. A first one that involves the construction of monitoring indices through a non-parametric methodology that uses an empirical probability function to adjust to the behavior of the variables; this methodology is applicable to both the precipitation and the rest of the simulated hydroclimatic variables being evaluated.

A second part that includes two objectives, on the one hand the implementation of a land surface model in the entire La Plata Basin to simulate hydrological fields of variables with difficult estimation. On the other hand, this has allowed to develop a climatollogy of droughts during the period 1980-2010, through standardized indicators of the simulated variables, which were constructed using the non-parametric methodology.

Finally, a system for monitoring and predicting drought occurrences in this region of South America was established. The forecasts were made by forcing the surface model with predicted 9 months leads variables. The forecasting skills of the proposed methodology was evaluated by comparing at a particular date predicted situations with simulated situations at near real time.

Índice general

Dedicatoria	IX
Agradecimientos	XI
Resumen	XIII
Abstract	XIII
1. Introducción.	1
1.1. Motivación	7
1.2. Objetivos	8
1.3. Organización de la Tesis	8
2. Metodología de Construcción de Índices de Monitoreo.	9
2.1. Certeza que presenta el Reanálisis del CFSR.	9
2.1.1. Descripción del Reanálisis del CFSR.	10
2.1.2. Descripción del Análisis del CPC.	11
2.1.3. Definición de Zonas.	12
2.1.4. Cuantificación de las diferencias entre CFSR y CPC.	14

2.2. Índice de Monitoreo de Precipitación.	20
2.2.1. Metodología. Construcción del Índice de Precipitación Estandarizado [SPI] no paramétrico.	21
2.2.2. Evaluación del SPI.	23
2.3. Conclusión.	27
3. Implementación del Modelo Hidrológico VIC en la cuenca del Plata.	29
3.1. Descripción y características del Modelo Hidrológico VIC.	29
3.2. Aplicación en la región de estudio.	32
3.2.1. Parámetros.	33
3.2.2. Análisis de Sensibilidad de Parámetros.	36
3.2.3. Análisis de Sensibilidad de Variables.	41
3.2.4. Calibración de Parámetros.	43
3.2.5. Validación.	50
3.3. Conclusión.	52
4. Climatología de Eventos Extremos Secos.	55
4.1. Tipos de Sequías y Variables.	57
4.2. Indicadores Estandarizados.	60
4.3. Climatología de Sequías.	62
4.3.1. Frecuencias.	62
4.3.2. Duración.	66
4.3.3. Severidad y Extensión Areal.	69

4.3.4. Análisis de Cultivos.	74
4.4. Conclusión.	78
5. Sistema de Pronóstico y Monitoreo de Eventos Extremos.	81
5.1. Monitoreo de Eventos Extremos Secos.	82
5.1.1. Distribución Espacial del evento 2008/9.	85
5.1.2. Distribución Espacial del evento 2011/12.	87
5.2. Pronóstico a 9 meses.	90
5.3. Conclusión.	96
6. Conclusiones. Discusiones y Trabajos Futuros.	99
6.1. Conclusiones	99
6.2. Discusión y Trabajo a Futuro.	102
A. Anexo.	105
A.1. Balance de Agua	105
A.1.1. Evaporación del Canopeo	106
A.1.2. Transpiración de la Vegetación	107
A.1.3. Evaporación del Suelo Desnudo	107
A.1.4. Ecurrimiento Directo y Flujo Base	108
A.1.5. Humedad del suelo	110
A.2. Balance de Energía	111
Bibliografía	112

Índice de cuadros

2.1. Correlación temporal entre datos de precipitación estacional de CFSR y de CPC para el período 1980-2010, correspondiente a la zona 1 y zona 2.	19
3.1. Parámetros de Vegetación y de Suelo que utiliza el modelo VIC, rango físico y fuente de la información.	33
3.2. Valores de parámetros para la condición inicial base del análisis de sensibilidad y valores modificados para las 2 condiciones consideradas.	36
3.3. Parámetros de suelo modificados en +20 % (negro) y en - 20 % (azul) respecto de la condición BASE. Variación percibida en cada variable del modelo expresadas en porcentaje, respecto de la situación BASE. Valores promedios referentes a la Zona 1. El resaltado indica el parámetro que registra la mayor variación de una variable en particular	39
3.4. Ídem Tabla 3.3 pero con valores referentes a la Zona 2.	39
3.5. Set de parámetros usados en la calibración de la humedad del suelo simulada, para el período 1985-1990. Medición del ajuste de cada set de parámetros en la cuenca del Plata, utilizando BIAS, el error cuadrático medio estandarizado (SRMSE), y el coeficiente de Nash-Sutcliffe (NSE), como funciones objetivos. . .	46
3.6. Validación del set de parámetros de mejor ajuste en la cuenca del Plata para el período 1991-2010. Utilizando BIAS, el error cuadrático medio estandarizado (SRMSE), y el coeficiente de Nash-Sutcliffe (NSE), como funciones objetivos. . .	51

4.1. Coeficientes de Correlación entre series temporales de Indicadores de escalas de 3, 6 y 9 meses, y variables de superficie P , Evt , R , HdS_1 , HdS_2 y HdS_3 , correspondientes a la zona 2.	59
4.2. Clasificación de eventos extremos de acuerdo a valores de SPI.	61
4.3. Coeficientes de determinación R^2 entre Severidad y Anomalías de rendimiento de cultivos de las provincias de Santa Fe (SF) y Córdoba (Córdoba), utilizando indicadores de escala temporal de 3 meses.	78
5.1. Coeficiente de correlación R^2 entre indicadores simulados a tiempo casi real (TCR) e indicadores simulados a 9 meses iniciados en dic.2015, ene.2016 y feb.2016.	93

Índice de figuras

1.1. Cuenca del río de La Plata con sus ríos principales.	6
2.1. Climatología de la variable precipitación en [mm] durante el período 1980-2010. a) Obtenida de CFSR, b) Obtenida de CPC.	11
2.2. Ciclo Anual medio [mm/d] del período 1980-2010 y Coeficiente de Correlación (r) para la zona 1 y zona 2, entre los datos de CFSR en línea azul y de CPC en línea roja.	13
2.3. Diagrama de dispersión entre valores mensuales de Precipitación de CFSR y CPC, correspondiente al período 1980-2010. a) Correspondiente a la Zona 1 y b) a la Zona 2.	14
2.4. Climatología de Precipitación para el período 1980-2010 de CFSR (azul) y de CPC (rojo). a) Valores promedio para la zona 1, b) Idem para zona 2. Diferencias entre climatologías de CFSR y CPC, c) en zona 1 y d) en zona 2.	15
2.5. a) Diferencias entre climatologías de precipitación de CFSR y de CPC expresadas en [mm]. b) Correlación temporal de datos mensuales de precipitación de CFSR y de CPC. Ambos análisis realizados durante el período 1980-2010	16
2.6. Diferencias de precipitación media estacional en [mm] entre CFSR y CPC para el período 1980-2010. a) DEF, b) MAM, c) JJA, d) SON	18

2.7. a) Función de probabilidad empírica asociada a la precipitación. b) Inversa de la función de distribución estandarizada, para los valores de probabilidad asociados a la precipitación.	22
2.8. a) Series temporales medias areales de SPI3 para la zona 1 referente al período 1980-2010, basadas en datos mensuales de precipitación de CFSR (azul) y basadas en datos de CPC (rojo). b) Ídem para SPI6. c) Diferencias en la zona 1 entre series temporales de SPI3 [CFSR – CPC], y d) Ídem para SPI6.	24
2.9. Ídem figura 2.8 pero referido a zona 2.	25
2.10. Diagramas de dispersión para el período 1980-2010 a) entre SPI3 (CFSR) y SPI3 (CPC) para la zona 1. b) Idem para SPI6. c) entre SPI3 (CFSR) y SPI3 (CPC) para la zona 2. d) Idem para SPI6.	26
2.11. a) Error cuadrático medio (<i>RMSE</i>) para valores de SPI3 entre fuentes de CFSR y CPC para el período 1980-2010. b) Ídem para SPI6.	27
3.1. Esquema de parametrización de los procesos de superficie del modelo VIC (Cherkauer et al., 2003).	31
3.2. Curvas de Capacidad de Infiltración Variable y de generación del Flujo Base. Ejemplos de estimación para diferentes parámetros del suelo.	35
3.3. Valores medios diarios del período 1985-1990 correspondientes a la simulación con la condición BASE de los parámetros. a) Evapotranspiración (<i>Evp</i>), b) Humedad del Suelo en capa 1 (<i>HdS₁</i>), c) Esguerrimiento Directo (<i>R</i>), d) Humedad del Suelo en capa 2 (<i>HdS₂</i>), e) Flujo Base (<i>B</i>), f) Humedad del Suelo en capa 3 (<i>HdS₃</i>).	38
3.4. Diferencias relativas entre valores medios diarios simulados durante el período 1985-1990, de la condición de sequía propuesta y de la condición sin modificar. Para las variables a) Evapotranspiración, b) HdS en capa 1, c) R, d) ídem b en capa 2, e) B, f) ídem b en capa 3.	42

3.5. Muestra regiones donde estimaciones de los sensores [activos (azul) / pasivos (marrón)] presentan los menores errores en relación con mediciones in situ, las zonas en blanco registran poca cantidad de mediciones. Tomado de Dorigo et al. (2010). 44

3.6. a) Diferencias relativas entre valores medios de humedad del suelo (condición inicial) correspondiente a la capa superior del suelo y las estimaciones satelitales, durante el período 1985-1990. b) Correlación temporal entre estimaciones y simulaciones a paso de tiempo mensual durante el mismo período y para la misma capa de suelo. 45

3.7. Análisis entre estimaciones satelitales y simulaciones de HdS_1 , mediante: a) BIAS (%), b) SRMSE, c) NSE para el set 1 de parámetros. d), e), f) ídem a), para el set 2 de la tabla 3.3. 47

3.8. Análisis entre estimaciones satelitales y simulaciones de HdS_1 , mediante: a) BIAS (%), b) SRMSE, c) NSE para el set 3 de parámetros. d), e), f) ídem a), para el set 4 de la tabla 3.3. 48

3.9. Series temporales de datos mensuales para la cuenca del Plata durante 1985-1990, de humedad del suelo estimada (azul) versus simulada (negro). a) Simulación con la condición BASE de parámetros. b) Simulación con set de parámetros del modelo calibrado. 49

3.10. Diagramas de dispersión entre estimaciones satelitales y simulaciones de HdS, para la cuenca del Plata durante 1985-1990. a) Simulación con condición BASE de parámetros. b) Simulación con set de parámetros del modelo calibrado. 50

3.11. Análisis entre las estimaciones satelitales y las simulaciones de HdS_1 . Durante la etapa de Validación 1991-2010: a) BIAS (%), b) SRMSE, c) NSE. 51

3.12. IZQ: Series temporales de datos mensuales de HdS estimada (azul) versus simulada (rojo). DER: Diagrama de dispersión entre estimaciones satelitales y simulaciones de HdS. Para la cuenca del Plata durante el período de validación 1991-2010. 52

4.1. Regiones de mayor intensidad de producción en relación a cultivos de Soja, Maíz, y Trigo. En el panel final se muestra la distribución de superficie sembrada. Fuente: <i>news.agrofy.com.ar</i> . Cruzate y Casas (2012)	56
4.2. Series temporales a paso mensual de la cuenca del Plata durante el período 1980-2010 de las variables simuladas. a) Precipitación, b) Humedal del suelo en capa 1, c) Evapotranspiración, d) ídem b en capa 2, e) Escorrentía, y f) ídem b en capa 3.	58
4.3. Definición de evento seco mediante el uso de umbral. Tomado de Yevjevich, 1967.	62
4.4. Probabilidad de ocurrencia de eventos menores al umbral durante el período 1980-2010, de acuerdo a indicadores de 3 meses a) SPI3, b) SEI3, c) SSI3, y d) SRI3; e), f), g) y h) ídem para indicadores de 6 meses.	63
4.5. Series de tiempo de frecuencias acumuladas según indicador en zona 2: a) SPI3 (rojo), SPI6 (azul) y SPI9 (negro), b) ídem a) para SEI, c) ídem a) para SSI, y d) ídem a) para SRI.	64
4.6. Histograma de Frecuencias en zona 2 para indicadores de 3 meses en verde, a) SPI3, b) SEI3, c) SSI3 y d) SRI3; y para indicadores de 6 meses en azul, e) SPI6, f) SEI6, g) SSI6 y h) SRI6.	65
4.7. Histogramas de Frecuencias de sequías moderadas a extremas en zona 2, de acuerdo a diferentes duraciones. a)SPI3/6, b)SEI3/6, c)SSI3/6, y d) SRI3/6. . .	66
4.8. Diagramas de Pareto para índices de 3 meses. a) SPI, b)SEI, c) SSI, d) SRI. . .	67
4.9. Ídem figura 4.8 para índices de 6 meses.	68
4.10. Distribución espacial de las mayores frecuencias de eventos secos, para 1 mes de duración: a)SPI3, b)SEI3, c)SSI3, y d)SRI3. Para de 2 meses de duración: e)SPI3, f)SEI3, g)SSI3, y h)SRI3	69
4.11. Ídem figura 4.10 pero con indicadores de escala de tiempo 6 meses.	70

4.12. Severidad de sequías detectadas en zona 2, según indicadores de escala de tiempo 3 meses en rojo y 6 meses en azul: a)SPI3/6, b)SEI3/6, c)SSI3/6 y d) SRI3/6.	71
4.13. Extensión areal de sequías en zona 2, expresadas en $[km^2]$ x [1000] según in- dicadores con escala de tiempo 3 meses en rojo y 6 meses en azul: a)SPI3/6, b)SEI3/6, c)SSI3/6 y d) SRI3/6.	72
4.14. Diagramas de dispersión entre severidad y extensión areal de sequías según índi- ces: a) SPI3, b) SPI6, c) SEI3 y d) SEI6.	74
4.15. Ídem figura 4.14 para índices: a) SSI3, b) SSI6, c) SRI3 y d) SRI6.	75
4.16. Valores de rendimiento de a) maíz, c) trigo y e) soja; y anomalías de rendimiento de b) maíz, d) trigo y f) soja, expresadas en $[kg\ ha^{-1}]$, para las provincias de Santa Fe (verde), Córdoba (rojo). 1969-2016.	76
5.1. Esquema de funcionamiento del sistema de monitoreo, a través del uso de for- zantes a tiempo casi real.	82
5.2. Series de tiempo del período ENE 2005 a JUN 2016 en zona 2: a) Anomalías de Precipitación en [mm]. Indicadores Estandarizados: b) SPI3 (negro), SPI6 (rojo) y SPI9 (azul); c), d) y e) ídem b) para SEI, SSI y SRI respectivamente.	83
5.3. Series de tiempo de Severidad de Sequías del período ENE 2005 a JUN 2016 en zona 2 correspondiente a: a) SPI3 (rojo) y SPI6 (azul), b), c) y d), ídem a) para SEI, SSI y SRI, respectivamente.	85
5.4. Monitoreo de eventos secos, condición de inicio de la sequía evaluada en el mes de julio de 2007 a través de: a) SPI3, b) SEI3, c) SSI3 y d) SRI3.	86
5.5. Monitoreo de eventos secos, condición de finalización de la sequía en el mes de noviembre de 2009, a través de: a) SEI3, b) SEI6, c) SRI3 y d) SRI6.	87
5.6. Monitoreo de eventos secos, condición de inicio de la sequía evaluada en el mes de diciembre de 2010, a través de: a) SPI3, b) SEI3, c) SSI3 y d) SRI3	88

5.7. Monitoreo de eventos secos, condición de finalización de la sequía en el mes de noviembre de 2012, a través de: a) SEI3, b) SEI6, c) SRI3 y d) SRI6.	89
5.8. Funcionamiento del sistema de monitoreo y pronóstico basado en el Modelo VIC, a través del uso de forzantes a tiempo casi real y forzantes pronosticados a 9 meses.	91
5.9. Series de tiempo con datos de pronóstico a tiempo casi real en zona 2, desde diciembre 2014 a junio 2016 para: a) SPI3 (negro). Conjuntamente con simulaciones pronosticadas a 9 meses iniciadas en dic.2015 (rojo), ene.2016 (verde) y feb.2016 (azul) del mismo indicador. b) ídem a) para SPI6, c) ídem a) para SSI3 y d) ídem a) para SSI6.	92
5.10. Fila 1: Diferencias entre pronóstico a tiempo casi real de a) SPI3 (MAY 2016) y pronósticos a 9 meses, iniciados en: b) dic.2015, c) ene.2016, y d) feb.2016. Fila 2: ídem fila 1 pero e), f), g), y h) refieren a SPI6.	93
5.11. Ídem figura 5.10, pero fila 1 referido a SSI3 y fila 2 a SSI6.	94
5.12. Evaluación de pronósticos en mayo 2016: Fila 1, a) situación a TCR SPI3 en mayo 2016. b) BIAS entre pronóstico a TCR y pronósticos a 9 meses iniciado en dic.2015, c) ídem a), para pronóstico iniciado en ene.2016, y d) ídem a), para pronóstico iniciado en feb.2016. Fila 2: Ídem fila 1 pero referente a SPI6.	95
5.13. Ídem figura 5.12, pero fila 1 referido a SSI3 y fila 2 a SSI6.	96
A.1. Curva de capacidad de infiltración variable del modelo <i>Xianjiang</i> (Wood et al.,1992).	108

Capítulo 1

Introducción.

Los eventos extremos secos tienen la particularidad de ser uno de los desastres naturales que afectan a mayor cantidad de gente y además también los que producen mayores pérdidas económicas en una sociedad (Wilhite, 2000; Mo, 2008). Particularmente esto se debe a que estos eventos son difíciles de detectar en su inicio y una vez que se lo hace es debido a que los efectos sobre una región son visibles (Wilhite, 2006). Diversos autores especialistas en la temática han abordado este tema para aportar mayor claridad, tratando de determinar en detalle características de las sequías, así como el monitoreo, inicio y finalización. Por ejemplo en Svoboda et al. (2002) y Mo (2011) han sugerido que un enfoque apropiado para detectar sequías desde su comienzo, consiste en tener un mejor entendimiento de las condiciones que dan inicio a las mismas, lo que mejoraría su sistema de alerta. Las mejoras en el monitoreo de los eventos secos y en las capacidades de los sistemas de pronósticos, van a permitir que haya mejores condiciones para la detección de sequías, mejores planes para su mitigación y como resultado una reducción del impacto en la sociedad (Svoboda et al., 2002). Las consecuencias que los eventos secos producen una vez ocurridos, se pueden cuantificar en distintos sectores de la sociedad, como por ejemplo: en la agricultura, en el manejo de los recursos hídricos y en la generación de energía de origen hidráulico (Mo y Schemm, 2008). Estas consecuencias se traducen directamente en impactos en la economía de la región afectada.

A nivel mundial los eventos secos suelen afectar indistintamente a diferentes regiones. Por ejemplo, en la India, uno de los países más vulnerables a este tipo de eventos, en los últimos 50 años se ha reportado un evento seco al menos una vez cada 3 años (Mishra y Singh, 2010). En otro artículo, los mismos autores Mishra y Singh (2009) han estudiado características de los eventos secos para una región de India, y detectaron cambios en las curvas de severidad-extensión-frecuencia de sequías mediante la evaluación de distintos escenarios futuros de Cambio Climático. Mientras que también han estudiado el tiempo de duración de sequías y el tiempo entre inicios de dos sucesos secos consecutivos (Mishra et al., 2009), a través de índices estandarizados de precipitación (Standardized Precipitation Index, SPI por su sigla en inglés) a distintas escalas de tiempo, y encontraron que los valores medios de ambos tiempos aumenta-

ban a medida que aumentaba la escala de tiempo del índice con que se lo analizaba. Unos años antes Lloyd-Hughes y Saunders (2002) realizaron una climatología de eventos secos en todo el continente Europeo, a través de la comparación de SPI en distintas escalas temporales (3, 6, 9, 12, 18, y 24 meses) y también de indicadores de severidad de sequía de Palmer (Palmer Drought Severity Index, PDSI por su sigla en inglés), basados en datos mensuales de precipitación durante el período 1901-1999, encontrando una tendencia hacia la sequía en la región central de Europa y el oeste de Rusia; así como también resultados casi idénticos entre los índices de 12 meses (SPI12) y PDSI.

En América del norte, una serie de estudios han dado cuenta del análisis de eventos secos mediante la construcción de índices de monitoreo basados en datos de estaciones de medición. Byun y Wilhite (1999) propusieron una serie de índices de paso diario para realizar una cuantificación objetiva de características de las sequías como, el comienzo, la duración, y el final de un período de déficit, en la región de las Altas Planicies de Estados Unidos (EU) durante el período 1960-1996; y determinaron que una definición más apropiada de la duración de las sequías se obtiene considerando los déficits del índice de estandarizado de precipitación diaria entre períodos de sequías. El índice estandarizado de precipitación (SPI) que utilizan datos mensuales, se usó para monitorear la sequía de 1996 en todo EU (Hayes et al., 1999), y también para compararlo con el índice de Palmer (PDSI); y destacaron que el índice de un mes (SPI1) pudo detectar con un mes de anticipación, respecto al PDSI, el comienzo de la sequía de 1996. Por otro lado el índice SPI posee la característica que puede determinarse para distintas escalas de tiempo. Una revisión de la aplicación de índices de monitoreo de sequías en todo EU, fue realizada posteriormente por Heim (2002) destacándose la falta de simpleza en la estimación del índice PSDI. En ese mismo año Keyantash y Dracup (2002) evaluaron una serie de índices de distintos tipos de sequías (meteorológicas, hidrológicas y agrológicas) en una región del estado de Oregon; ponderando 6 propiedades en cada indicador durante 1976-1999. Determinando que la mejor ponderación para sequías meteorológicas en esa región la tenían los índices de percentiles de precipitación y el SPI, para sequías hidrológicas la tenía el déficit de agua total, y el índice computado de humedad del suelo era el mejor ponderado para las sequías agrológicas. Un poco más al norte de Estados Unidos, Quiring y Papakryiakou (2003) estudiaron las sequías agrícolas mediante 4 índices; SPI, PDSI, el índice Z de Palmer y el índice de sequía de la NOAA (NOAA Drought Index, NDI por su sigla en inglés), para el período 1961-1999; que luego fueron vinculados con la producción de trigo en la región sur de Canadá estableciendo que el índice Z de Palmer era el mejor indicador de los 4 evaluados para medir sequías agrícolas.

Por otro lado se han realizado investigaciones de sequías, también en EU, basadas en datos simulados a través de modelos de superficie. En Mo (2008) se usaron modelos de superficie (VIC y NOAH) para construir índices SPI, SRI (similar al SPI pero sobre la escorrentía R), y percentiles de humedad del suelo, basados en datos simulados por estos modelos; y se los usó para clasificar sequías durante el período 1950-2000. Entre las conclusiones del trabajo se

estableció que los índices derivados del modelo VIC poseían mejor correlación entre sí que los mismos índices evaluados del modelo NOAH. Este resultado indica una respuesta más rápida de la escorrentía ante un evento de precipitación, sobre datos obtenidos de VIC en relación a los de NOAH. Posteriormente en Mo (2011) se estudió el comienzo y final de eventos de sequía, el estudio se realizó con indicadores derivados de datos simulados durante el período 1917-2007 utilizando 3 modelos (VIC, NOAH y SAC). Se determinó que el comienzo de las sequías es más predecible ya que el inicio se prolonga por más tiempo demorando así su ocurrencia, pero la finalización del evento puede ocurrir de manera imprevista mediante una abundante lluvia. Por otro lado, el uso de datos derivados de simulaciones ha hecho posible también estudios de sequías a nivel regional y global. Sheffield y Wood (2007) analizaron características de las sequías en todo el mundo durante la segunda mitad del siglo pasado (1950-2000) mediante índices mensuales de percentiles de humedad del suelo, encontrando que las sequías de corta duración [≤ 6 meses] prevalecen en regiones tropicales y de latitudes medias. Las sequías de media duración (7 meses-12 meses) en regiones de latitudes medias y altas. Mientras que las sequías mayores a 12 meses de duración eran restringidas solo a la región Sub-Sahariana en África y a latitudes altas del hemisferio norte. Estos mismos autores también han estudiado durante el mismo período (1950-2000) la variabilidad y las tendencias de las sequías regionales y globales (Sheffield y Wood, 2008), mediante índices de humedad del suelo derivados de simulaciones hidrológicas; estableciendo que la tendencia de ciertas propiedades de las sequías como duración, intensidad y severidad, están decreciendo a nivel global. En el continente americano, las tendencias son mayormente negativas y significativas. No obstante a partir de la mitad de la década de 1970, existe un cambio en la tendencia hacia las sequías a nivel global, específicamente sobre altas latitudes norte.

Los índices utilizados para el monitoreo de sequías han ido cambiando con el tiempo a medida que se fueron evaluando otros indicadores con mejores prestaciones y/o facilidades para su estimación. Keyantash y Dracup (2002) han establecido ciertas características que deben poseer los indicadores de sequía, y de acuerdo con esto los mismos deben ser estadísticamente robustos, de fácil determinación a través de un procedimiento comprensible y claro. Por ejemplo existen indicadores utilizados para el monitoreo de sequías, como el PDSI (Palmer, 1965) que ha sido muy usado a nivel mundial hasta el surgimiento del SPI (McKee et al., 1993). Este último ha resultado ser un indicador mucho más simple en su cálculo que el de Palmer, además de poder estimarlo a distintas escalas de tiempo y solo con una variable para su cálculo, la precipitación. Estas cualidades han posicionado mejor al SPI por sobre el PDSI, y ha dado lugar a la construcción de índices que utilizan la metodología del SPI, pero con otras variables, como por ejemplo la escorrentía, la humedad del suelo, evapotranspiración, entre otras. En esta línea, por ejemplo, Vicente Serrano et al. (2010) han introducido un indicador para el monitoreo de sequías que utiliza la metodología del SPI, y como variables de entrada las diferencias entre la precipitación y la evapotranspiración (P-E), denominado SPEI; siguiendo un concepto multiescalar, es decir diferentes escalas de tiempo. Este indicador se ha evaluado con datos de medición en 11 estaciones de características climáticas diferente en distintas partes del mundo

durante el período 1910-2007, y se lo comparó con los índices SPI y PDSI. Se encontró que el SPEI es útil para detectar, monitorear y analizar sequías al igual que los otros dos índices; no obstante de los indicadores que utilizan a la evapotranspiración como variable de entrada para caracterizar sequías, SPEI es el único que por tener una aplicación multiescalar le permite identificar diferentes tipos de sequías y sus efectos.

En la región del Sudeste de América del Sur (SESA por su sigla en inglés) se encuentra la Cuenca del Plata que es una de las más importantes del planeta por su tamaño y ubicación, abarca más de 3.100.000 km^2 , se ubica entre los 67° hasta los 43° W de longitud y desde 14° hasta los 38°S de latitud. Se extiende a través de 5 países, Argentina, Bolivia, Brasil, Paraguay y Uruguay. Es una región económicamente muy importante donde se concentra más del 50 % del producto bruto nacional (PBN) de toda Sudamérica y más del 70 % del PBN de los 5 países combinados (Tucci, 2001; Krepper y Zucarelli, 2010). En la parte Argentina de la cuenca se producen más del 90 % de los cultivos del país y donde crece más del 70 % del ganado bovino (Mechoso et al., 2001).

Fundamentalmente los factores de producción más importantes lo constituyen la agricultura y la ganadería, y son altamente sensibles a la variabilidad y los extremos climáticos, debido a que dependen en gran medida de la lluvia natural para su desarrollo (el riego representa menos del 3 % de la superficie total cubierta por el trigo, el maíz y la soja, véase, por ejemplo, Siebert et al., 2013). El maíz es uno de los cultivos más sensibles a los déficits de agua (Minetti et al., 2007), mientras que la producción de soja tiende a verse afectado por los extremos de temporada húmeda y seca (Penalba et al., 2007). Existe una relación de vinculación definida entre dos características de los eventos extremos como son la frecuencia de ocurrencia y la duración de los mismos; de acuerdo a análisis estadísticos, la ocurrencia de eventos extremos en la región han demostrado que los períodos de exceso de agua o de déficit ocurren en diferentes escalas de tiempo, con una relación inversa entre la frecuencia y la duración (Krepper y Zucarelli, 2010), es decir que los eventos de mayor frecuencia tienden a ser de más corta duración, así como los de baja frecuencia tienden a prolongarse más en el tiempo. Si bien es cierto que la variabilidad y los eventos extremos (EE) por lo general impactan en forma negativa sobre los factores productivos, existen evidencias de que un incremento de la precipitación media en una región donde el recurso hídrico es escaso puede favorecer la actividad productiva. Se identificaron cambios en los patrones de precipitación (Minetti y Vargas, 1998; Castañeda y Barros, 2001) con tendencia positiva a partir de 1950 (Krepper y Sequeira, 1998; Krepper y Zucarelli, 2010), este aumento de precipitación produjo un corrimiento de isohietas hacia zonas más áridas que derivó en una expansión de las prácticas de agrícolas hacia estas zonas y un aumento del área destinada a la producción de cultivos del orden de 100.000 km^2 (Berbery et al., 2006).

A través de varios trabajos previos se ha establecido, que en la región en donde se encuentra la cuenca del Plata, El Niño Oscilación Sur (ENSO por su sigla en inglés) es un forzante principal para el desarrollo y la duración de los eventos extremos (Penalba y Vargas 2004; Barrucand

et al. 2007; Vargas et al., 2010). Sin embargo, este mecanismo por sí solo no siempre conduce a intensas sequías o períodos húmedos. Como se discutió en Seager et al. (2010) y en Mo y Berbery (2011), la señal del ENSO sobre la sequía en SESA se hace más intensa y con una forma espacial mejor definida cuando la fase fría de ENSO es concurrente con una fase caliente de las temperaturas de la superficie del mar en la región del Atlántico Tropical Norte (NTA por su sigla en inglés). Por el contrario, cuando cada uno de los modos se encuentra en sus fases opuestas, se hace más intenso y mejor definido el evento húmedo. Además de estos forzantes, existen factores regionales y locales que pueden contribuir a una modulación del evento extremo una vez que se inician (Mo y Schemm 2008). La época del año, el transporte de humedad, y las condiciones de humedad del suelo, son todos factores que influyen de un modo u otro en la duración e intensidad de los eventos. Otro factor importante son las circulaciones atmosféricas que pueden obstaculizar el desarrollo de sistemas de precipitación durante largos períodos de tiempo. En este sentido, un caso relevante es la sequía de 1962, cuando un anticiclón persistente bloqueó el suministro de aire cálido y húmedo de Brasil y el Océano Atlántico, sometiendo la mayor parte de la Argentina a las condiciones de sequía (Malaka y Núñez 1980).

Los recursos hídricos de la cuenca son la base del desarrollo económico y permiten abastecer a una de las regiones más densamente pobladas de Sudamérica (Berbery y Barros, 2002), en la que habitan más de 100 millones de personas y donde el 87 % de la población se ubica en las regiones urbanizadas (UNESCO-WWAP, 2007). Los 3 ríos más importantes que dan forma a la cuenca son el río Paraná, el río Uruguay y el Paraguay que es tributario del Paraná (figura 1). La mayor parte de la cuenca se extiende sobre Brasil donde ocupa 1.415.000 [km²], y el resto se reparte con unos 920.000 [km²] en Argentina, 410.000 [km²] en Paraguay, 205.000 [km²] en Bolivia, y 150.000 [km²] en Uruguay (García y Vargas 1996). Cerca del 70 % del agua que escurre por los ríos de la cuenca ha precipitado en Brasil, mientras que sólo un tercio de la cuenca aporta 500 [m³ s⁻¹] sobre un caudal medio de alrededor de 23000 [m³ s⁻¹] (García y Vargas 1998). Este valor representa aproximadamente un 20 % del caudal medio que genera toda la cuenca en un año para una precipitación media de 1100 [mm] y el 80 % que resta se consume como evapotranspiración e infiltración (Mechoso et al., 2001).

Los eventos extremos en la región han experimentado cambios en la forma en que se manifiestan en cuanto a su ocurrencia y permanencia. Existen registros tan antiguos desde fines del siglo XIX reportados por Ameghino (1884) quien sospechaba, ya por esos años, que los cambios en la frecuencia de los eventos extremos eran debido a las prácticas de cambio de suelo que se llevaban a cabo en la época Colonial alrededor del siglo XVII, cuando la vegetación natural que retenía los excedentes de agua fue removida y cambiada por cultivos. Estudios más actuales (por ejemplo, Barrucand et al., 2007; Vargas et al., 2010) han reportado que durante la primera mitad del siglo XX la frecuencia de los eventos secos era mayor y esa frecuencia comenzó a decaer a partir de la segunda mitad del mismo siglo. Si bien es cierto que hay estudios que muestran un incremento en la precipitación (ver referencias previas) y una reducción en la cantidad de días secos durante el siglo XX (Penalba y Vargas 2008; Naumann et al., 2008;



Figura 1.1: Cuenca del río de La Plata con sus ríos principales.

Vargas et al., 2010), también es importante lo destacado en Krepper y Zucarelli (2010) y en Chen et al., (2010) que establecieron que la tendencia creciente detectada en la precipitación podría reducirse en la primera década del siglo XXI; de concretarse esta aseveración podría traducirse en sequías más frecuentes que impactarían en las actividades agrícolas.

Los impactos de los eventos secos se ponen en evidencia mayormente en la agricultura y ganadería de la región. La sequía de 1988/1989 en Argentina se clasificó entre los peores eventos registrados debido al déficit de agua. La superficie cultivada se redujo en un 35 % y el rendimiento de los cultivos en un 15 %, resultando en una disminución del 44 % de la productividad y grandes pérdidas económicas (FMI, 1990). La sequía de 2003/4 es otro caso de un evento extremo con un perjuicio semejante: en septiembre de 2003 el déficit de agua en la provincia de Buenos Aires tuvo un gran efecto, debido a que coincidió con el momento crítico para el crecimiento del trigo, produciendo pérdidas del orden de los \$100 M de dólares solo en esa provincia (Galmarini, 2003). La sequía regional continuó, y en abril de 2004, la falta de agua en el río Uruguay llevó al cierre de trece de las catorce turbinas de la central hidroeléctrica de Salto Grande (Tirso Fiorotto, 2004; Penalba y Vargas, 2008). La duración de la sequía 2008/9 fue en su momento la más intensa de los últimos 50 años de registro (Skansi et al., 2009; Müller et al., 2014). La sequía más reciente en los últimos tiempos 2011/12 causó pérdidas del orden de \$2.500 M de dólares debido a sus impactos en la soja y el maíz (Webber, 2012).

Una herramienta que se puede aplicar para reducir los impactos de las sequías en la producción, agrícola, ganadera o de energía, es la construcción y utilización de un sistema de alerta y predicción de eventos extremos, que permitiría establecer con cierta anticipación la ocurrencia de sequías y monitorear su evolución en el tiempo para mitigar su impacto. Existen, a nivel global,

aplicaciones desarrolladas para cumplimentar estas tareas; por ejemplo el Sistema de Monitoreo de Sequías y Predicción (DMAPS por su sigla en inglés) desarrollado en la Universidad de Princeton (Luo y Wood, 2007). Este sistema, aplicado en Estados Unidos, utiliza un modelo de superficie forzado con datos de pronóstico, para generar campos a futuro y predecir los eventos. Un sistema similar, también, se aplica a la región del África Sub-Sahariana para monitoreo y predicción de sequías denominado ADM, que es la sigla en inglés de African Drought Monitor (Sheffield et al., 2014) también desarrollado en la Universidad de Princeton. Asimismo existen otros sistemas de predicción de sequías a nivel global como por ejemplo el desarrollado en la Universidad de California, que consiste en un Sistema Global Integrado de Monitoreo y Predicción de Sequías (GIDMaPs, Hao et al., 2014); el sistema utiliza información proveniente de varias fuentes como entrada del mismo, construye indicadores derivados de los datos de entrada de cada fuente, y posteriormente realiza un estudio multivariado para el monitoreo y predicción de eventos secos.

1.1. Motivación

Los eventos extremos secos son los fenómenos naturales que mayor impacto económico producen en la sociedad. Poder detectar características de las sequías tales como su inicio, su duración y finalización con cierta antelación, constituyen respuestas valiosas desde la perspectiva científica-académica; del mismo modo también lo son las medidas que puedan tomarse en consecuencia para prevenir los impactos. A través de este conocimiento y mediante su difusión a los tomadores de decisión, se podrá moderar la magnitud de los impactos, y trabajar en la mitigación de los mismos para contribuir a generar bienestar en la comunidad. En el SESA en general, y en la región argentina de la cuenca del Plata en particular, las consecuencias que producen los eventos extremos secos se encuentran relacionadas de manera directa con la producción agropecuaria. Por ejemplo de acuerdo al informe del INTA del año 2009 (Corti y Mendoza Gallo, 2012), la provincia de Santa Fe registró pérdidas económicas por \$347 M de pesos, contabilizando cultivos de soja, girasol, maíz, sorgo, caña de azúcar y trigo, solo en 4 departamentos del norte de la provincia debido a la sequía 2008/9; y además a consecuencia del mismo fenómeno hubo una caída del 6% de la producción vacuna.

El uso de una herramienta como el modelo hidrológico de Capacidad de Infiltración Variable (VIC), permite simular campos hidrometeorológicos de superficie, alguno de las cuales constituyen un registro de datos inexistente o poco extenso, y construir indicadores derivados que permitan monitorear la ocurrencia de evento extremos secos. Posteriormente establecer un sistema de predicción y alerta de eventos extremos secos resultará muy útil para disminuir los impactos, reducir las pérdidas económicas, y trabajar sobre la mitigación. Investigar a estos fenómenos mediante su detección a tiempo, describir su estado a través de sus características, y finalmente monitorearlos para informar a los tomadores de decisión acerca de su ocurrencia constituye la motivación de este trabajo.

1.2. Objetivos

Con el desarrollo de esta tesis se pretende abordar los siguientes objetivos:

- Investigar los mejores indicadores de sequías que permitan desarrollar un sistema de monitoreo de eventos extremos secos.
- Originar una climatología de eventos extremos secos para la región Argentina de la Cuenca del Plata, derivada de la implementación de un modelo hidrológico de superficie.
- Aplicar un modelo hidrológico para identificar los indicadores de variables superficiales más sensibles a las sequías, que permitan detectar y monitorear eventos extremos secos en la región.
- Implementar un sistema de alerta y predicción de eventos extremos secos, mediante la ejecución de un modelo hidrológico forzado por pronósticos estacionales.

1.3. Organización de la Tesis

Tendiendo a la concreción de los objetivos explicitados en el punto anterior, el presente trabajo se organiza de la siguiente manera. La introducción y estado del arte a nivel global y regional se expone en el capítulo 1, en donde también se describe la motivación y los objetivos. En el capítulo 2 se propone la implementación del uso de una metodología para la construcción de indicadores estandarizados basados en datos de reanálisis; previo a esto se realiza una evaluación del bias que presenta el reanálisis en la región del SESA cuando se lo compara con una fuente de datos grillados basados en observaciones. Una descripción del modelo hidrológico de Capacidad de Infiltración Variable, conjuntamente con su implementación en la cuenca del Plata, para generar una climatología de variables de estado simuladas, se presenta en el capítulo 3 donde se incluye además la calibración y validación del modelo. En el capítulo 4 se describe la climatología de eventos extremos secos analizando las características físicas de las sequías, de acuerdo a indicadores derivados de las variables que muestren más sensibilidad a las sequías. Un sistema para monitorear y predecir eventos extremos secos, utilizando el modelo hidrológico forzados con datos de pronóstico se presenta en el capítulo 5. Finalmente el capítulo 6 exponen las principales conclusiones, así como una discusión sobre este estudio y el trabajo a futuro.

Capítulo 2

Metodología de Construcción de Índices de Monitoreo.

2.1. Certeza que presenta el Reanálisis del CFSR.

De acuerdo a lo mencionado en la introducción y consecuente con lo establecido en Svoboda et al. (2002), el monitoreo de eventos extremos secos, la determinación de su inicio, su prolongación en el tiempo y posterior finalización; constituyen un enfoque apropiado y necesario para mejorar los sistemas de predicción y alerta de sequías. Además, un monitoreo eficiente de eventos secos debe considerar el comportamiento de la precipitación en esta zona de Sudamérica, específicamente la climatología de precipitación durante el período de análisis 1980-2010 y también la determinación del ciclo anual en regiones específicas. La región de estudio de este trabajo se extiende de norte a sur entre los 14° hasta los 38° de latitud sur, y de este a oeste de los 43° hasta los 68° de longitud oeste, de aquí en adelante denominada SESA correspondiente a el Sudeste de Sudamérica.

En la determinación de la climatología y posteriormente en la estimación del ciclo anual se analizan dos fuentes de datos durante el mismo período 1980-2010, una de estas fuentes está basada en datos observados de precipitación, obtenidos de mediciones *in situ* e interpolados arealmente generando una grilla regular Lat/Lon de 0,5° (CPC, Chen et al., 2008). Mientras que la otra fuente la constituye la precipitación de un producto de reanálisis (CFSR, Saha et al., 2010), obtenida de un modelo global con resolución horizontal aproximada Lat/Lon de 0,3° (T382), NCAR Staff (Eds). 2013. "The Climate Data Guide: Common Spectral Model Grid Resolutions". (<https://climatedataguide.ucar.edu/climate-model-evaluation/common-spectral-model-grid-resolutions>). De acuerdo con uno de los objetivos principales de este trabajo, que corresponde a la implementación de un modelo de superficie en la cuenca del Plata forzado con campos del reanálisis del CFSR; en forma previa, se evalúa la bondad que presenta la precipitación del reanálisis para representar el comportamiento de la precipitación del análisis

del CPC. Teniendo en consideración que los datos del análisis son derivados de observaciones en estaciones de medición, y constituyen una buena medida del comportamiento real de esta variable. El resultado de la comparación entre ambas fuentes permitirá obtener no solo un grado de vinculación entre las fuentes, sino también una medida de la certeza que tiene el modelo del reanálisis en esta región de Sudamérica.

2.1.1. Descripción del Reanálisis del CFSR.

El Climate Forecast System Reanalysis (CFSR, por su sigla en inglés) es un modelo global de alta resolución desarrollado por el Centro Nacional de Predicción Ambiental (NCEP, por sus siglas en inglés) de Estados Unidos, implementado como reemplazo de los reanálisis previos NCEP/R1 (Kalnay et al., 1996) y NCEP/R2 (Kanamitsu et al., 2002) generados por el mismo NCEP. Esta versión de reanálisis ha sido mejorada, respecto de las R1 y R2, contemplando una resolución vertical y horizontal con mayor nivel de detalle (64 niveles de presión en vertical, y ≈ 38 km de resolución horizontal), una previsión de pronóstico que es generada a partir de un sistema acoplado atmósfera-océano-hielo-superficie, y asimilación de radiancia satelital (Saha et al., 2010, Silva et al., 2011, Blacutt et al., 2015). Uno de los principales objetivos en el desarrollo del CFSR fue el de crear estados iniciales para la atmósfera, el océano, el hielo y la tierra, y que sean a la vez los más avanzados y consistentes posibles con la versión de pronósticos posteriores (CFSv2, Saha et al., 2014), que se encuentran operacionales desde 2011. Datos de variables de CFSR, que se extiende originalmente desde 1979 hasta 2010, se utilizan durante el desarrollo del capítulo 3, como también para el capítulo actual donde se usa solo datos de precipitación. En ambos casos el período de ventana del estudio abarca desde 1980 a 2010 inclusive, mientras que la nueva versión de pronósticos CFSv2 es la fuente de la cual se extraen los forzantes que utiliza el modelo superficial para conducir las simulaciones que se utilizan tanto en los capítulos 4 y 5 de esta tesis.

Los datos del reanálisis que se usan en este capítulo corresponden a valores 6-horarios de la variable *prate* (tasa de precipitación 6-horaria promediada) expresada en $[kg\ m^{-2}\ s^{-1}]$ de acuerdo a como se obtiene de la página oficial del NCEP (<https://rda.ucar.edu/datasets/ds093.0/>) para la región Sudeste de Sudamérica y con la resolución espacial mencionada anteriormente. El valor total de precipitación en [mm] para las 6 horas del intervalo se obtiene multiplicando *prate* * 21600 que representa el factor de conversión entre $[kg\ m^{-2}\ s^{-1}]$ y [mm] para ese paso de tiempo, y equivale a la relación entre el tiempo total del intervalo y la densidad del agua. La figura 2.1a) muestra la climatología de la variable precipitación en [mm] para el período 1980-2010 obtenida del reanálisis.

La climatología de precipitación para el período 1980-2010 del CFSR se construyó sobre la base de datos diarios, es decir se transformó el archivo original de datos a paso de tiempo 6-horario a valores diarios expresados en [mm]. La región este sobre la costa de Brasil y también en el norte (figura 2.1a) exhibe los valores más altos superando los 1500 [mm] de precipitación

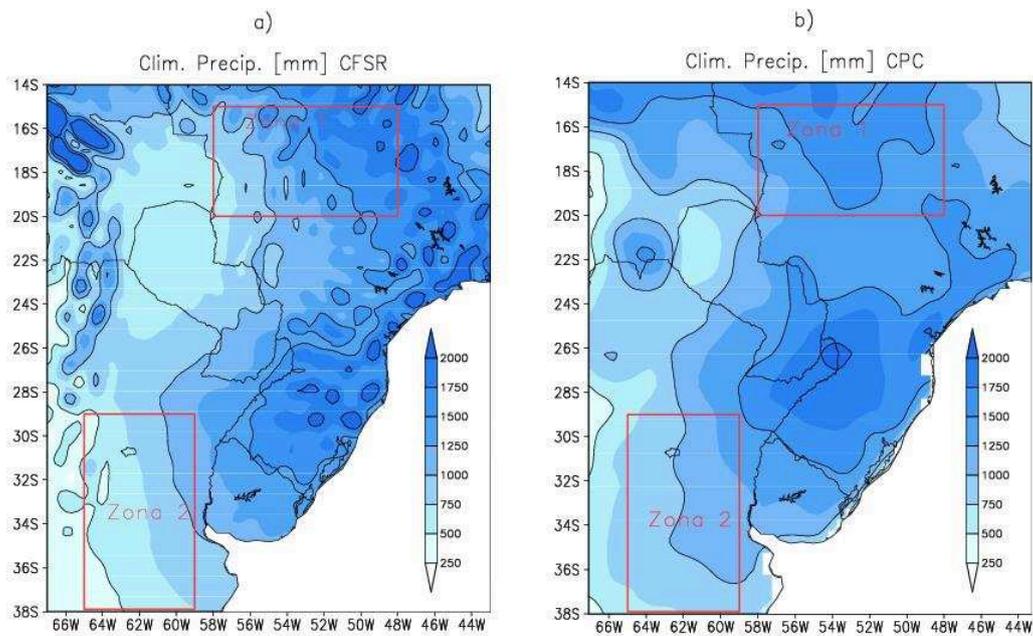


Figura 2.1: Climatología de la variable precipitación en [mm] durante el período 1980-2010. a) Obtenida de CFSR, b) Obtenida de CPC.

anual, mientras que existen pequeñas zonas cerradas dentro de esta región con valores que llegan a los 2000 [mm] por año; por otro lado hacia el oeste las precipitaciones disminuyen mostrando un gradiente de descenso este-oeste. Los registros anuales más bajos cercanos a 500 [mm] por año se observan en la parte norte de Paraguay y sureste de Bolivia, y también en la parte central de Argentina. Asimismo se observan altos registros de precipitación en regiones de montaña, valores medios anuales de 1500 [mm] localizados particularmente sobre Los Andes en el noroeste de Argentina y en la zona del Altiplano Boliviano, donde incluso aparecen regiones núcleos con valores de 2000 [mm] anuales. Estas pequeñas discontinuidades en la precipitación se encuentran en zonas de elevación importante y que constituyen divisorias de agua, en estas regiones los datos de precipitación del CFSR dejan de tener un comportamiento suavizado y comienza a observarse un comportamiento con una marcada variación espacial. Este efecto de la precipitación del reanálisis también ha sido destacado por otros autores, como por ejemplo en Silva et al. (2010) quienes además sugieren que puede deberse a la resolución espacial de los datos del reanálisis.

2.1.2. Descripción del Análisis del CPC.

La información de precipitación proveniente de estaciones de medición *in situ* ha constituido la fuente principal para documentar las características de la precipitación en la superficie terrestre, por sobre las mediciones de satélite, de radar, y de simulaciones numéricas (Chen y Xie, 2008). Esto se debe a que las estaciones de medición tienen un período de registro mucho más extenso que cualquiera de las otras fuentes mencionadas, y además es la única de todas ellas que se obtiene por medición directa, evitando la necesidad de realizar calibraciones y verificaciones de

los datos de medición indirecta, como ocurre con el resto de las fuentes (Xie et al., 2007a). El uso de datos de precipitación observada, datos derivados de estimaciones de satélite y radar, en conjunto con un modelo numérico, ha permitido generar datos de precipitación en grilla regular (Chen et al., 2008) que se denomina análisis. Los análisis producen datos que caracterizan el estado de la atmósfera en un período de tiempo mediante el uso de modelos numéricos que no son fijos en el tiempo. El Climate Prediction Center (CPC, por su sigla en inglés) ha desarrollado una red global de precipitación que se basa en datos observados en estaciones de medición, en esta red los datos de las estaciones son combinados con estimaciones satelitales para generar un análisis mejorado de precipitación global, denominado CMAP, que refiere a la sigla en inglés de CPC Merged Analysis Precipitation (Chen et al., 2008). Los datos de CMAP están constituidos por precipitación diaria determinados en una grilla regular global con resolución Lat/Lon de $0,5^\circ$, generada mediante un método de interpolación óptimo que considera una corrección debida a la orografía de la superficie, para el período desde 1979 hasta la actualidad.

En la figura 2.1b) se observan valores de precipitación media mayores a 1500 [mm] por año en la parte sur de Brasil extendiéndose algo más hacia el oeste que en la figura del reanálisis, con un núcleo de 2000 [mm] al año en el norte de Misiones. En la parte norte, principalmente en la región definida como zona 1 (ver recuadro superior en la figura 2.1), se observan valores anuales medios de precipitación entre 1500 [mm] y 2000 [mm]. Esta zona que constituye el límite norte de la cuenca del Plata, y más aún representa el límite con otras cuencas como la del Amazonas y la de Sao Francisco, se ubica en el núcleo del SAMS (Silva y Kousky, 2012) o South American Monsoon System por su sigla en inglés. Este sistema presenta un ciclo hidrológico bien marcado con elevada precipitación en la temporada de verano y muy baja o nula durante el invierno (Berbery y Barros, 2002; Silva et al., 2011). Al igual que ocurre en la figura 2.1a) los valores de precipitación media disminuyen hacia el oeste alcanzando un mínimo de 500 [mm] en la región de Los Andes poniendo en evidencia el mismo gradiente este-oeste; aunque a diferencia del comportamiento del CFSR, las variaciones en la climatología de los datos de CPC son más graduales y suavizadas. Probablemente esta última observación se deba a la diferencia de resolución entre los datos originales de cada producto. Otra característica que se destaca es que los valores de precipitación media del reanálisis tienden a subestimar levemente a los propios de CPC en la región central de Argentina. En este sentido existe un corrimiento, aunque leve, de las isóneas del reanálisis hacia la derecha, específicamente es más evidente en la línea de 1000 [mm] aunque también en la de 500 [mm] en la zona del Litoral Argentino de la figura 2.1a).

2.1.3. Definición de Zonas.

Como parte del estudio comparativo que se lleva a cabo en el presente capítulo, se hizo hincapié en dos regiones que presentan características climáticas y topográficas diferentes dentro de esta región de Sudamérica. La zona 1 se ubica en el corazón del Monzón Sudamericano (Silva y Kousky, 2012) y se extiende desde los 15° a los 20° de latitud sur y desde los 48° a los 58° de

longitud oeste (ver figura 2.1 y posteriores), y como se estableció con anterioridad representa una región que define los límites de 3 cuencas hidrológicas. Presenta un ciclo anual medio bien marcado con precipitaciones abundantes en verano y escasas en invierno como se puede ver en la figura 2.2a). El ciclo anual de precipitación que presenta una región puede afectar el desarrollo de las sequías que ocurran en la misma. En este sentido, en regiones donde el ciclo anual se encuentra bien definido, Mo y Berbery (2011) establecieron que las sequías pueden ser persistentes y tener una mayor duración; ya que un evento seco que ocurre hacia el final de la temporada de lluvias podría no encontrar recuperación y prolongarse hasta el inicio de la próxima temporada de lluvia. Para la región de la zona 1 el período de lluvias o temporada húmeda se extiende desde octubre a marzo y durante el resto del año las lluvias son escasas constituyendo la temporada seca; en la figura 2.2a) el ciclo anual medio muestra que los valores de precipitación llegan hasta los 9 [mm] por día para los meses de verano, mientras que no alcanzan a llegar a 1 [mm] por día durante los meses de invierno.

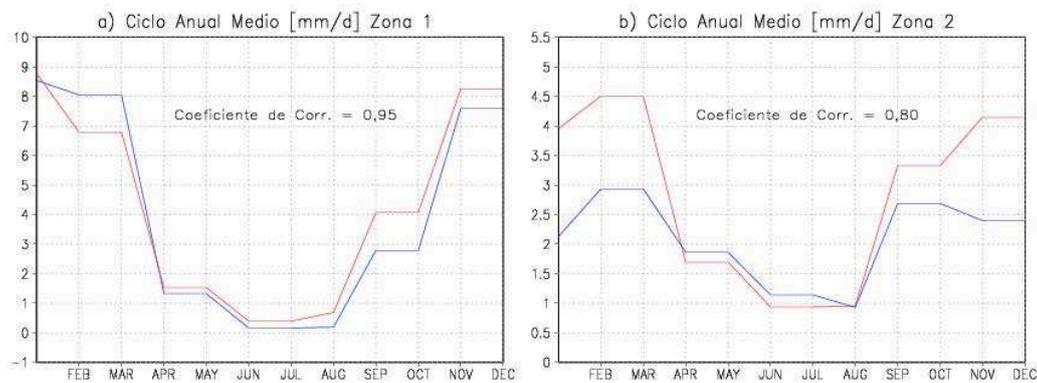


Figura 2.2: Ciclo Anual medio [mm/d] del período 1980-2010 y Coeficiente de Correlación (r) para la zona 1 y zona 2, entre los datos de CFSR en línea azul y de CPC en línea roja.

Se ha establecido a la zona 2 en la parte sur de esta región de Sudamérica, comúnmente denominada llanura Pampeana, como se puede ver en la figura 2.1 y posteriores, que abarca desde los 29° a los 38° de latitud sur y desde 59° hasta 65° de longitud oeste. Esta zona de Argentina presenta una importante actividad de producción agrícola y ganadera, donde se genera el 60% del PBI (Producto Bruto Interno) y el 80% de las exportaciones del país (Hartmann et al., 2003). La mayoría de los cultivos que se generan en la región Pampeana son los cultivos de grano (Viglizzo y Franck, 2006), entre los que se destacan el maíz, el trigo y la soja. Tradicionalmente el esquema de producción de granos alternaba con pasturas para la producción del ganado, en la actualidad el cultivo de pasturas se ha reducido casi por completo (Díaz Zorita, 2012) en favor de la producción de cultivos de grano durante todo el año. La zona 2 presenta un ciclo anual más débil con una distribución de la precipitación algo más uniforme que el ciclo de la zona 1, como se ve en la figura 2.2b) con una precipitación sustancialmente menor en verano que supera las 4 [mm/d], y algo mayor en invierno superando 1 [mm/d]. Esta situación algo más balanceada indica que las precipitaciones pueden suceder en cualquier parte del año, aunque prioritariamente en los meses más cálidos, y eventualmente influir en la duración de un evento seco. De esta manera una sequía que comienza en una estación del año

podría culminar en la siguiente (Mo y Berbery, 2011), reduciendo su duración, en oposición a la situación que presenta el fuerte ciclo de precipitación en zona 1.

2.1.4. Cuantificación de las diferencias entre CFSR y CPC.

El ciclo anual medio del período 1980-2010 para las zonas 1 y 2 se determinó utilizando a las dos fuentes de análisis, en azul en la figura 2.2) se presenta el ciclo para los valores del CFSR y los datos del análisis de CPC se muestran en rojo. Para cuantificar el grado de vinculación entre las dos fuentes evaluadas se estimó el coeficiente de correlación (r) para ambas series en zona 1 y zona 2. En la figura 2.2a) se observa que el ajuste del reanálisis respecto a los datos de CPC es muy bueno en la zona 1, representando el comportamiento del ciclo anual con un coeficiente de correlación (r) = 0,95. Se aprecia también que CFSR mide por exceso el ciclo medio durante los meses de enero-abril con una diferencia máxima entre febrero y marzo de 1 [mm] por día; luego durante los meses de abril-junio se tiene la mejor vinculación entre ambas fuentes, mientras que para el resto del año representa al ciclo por defecto con una diferencia máxima de igual magnitud entre septiembre y octubre. Por otro lado la figura 2.2b) muestra que el grado de ajuste del reanálisis, aunque de buena correlación (r) = 0,80, no es tan alto como en zona 1. Si bien en la representación existe un período que va desde abril a agosto donde existe una diferencia mínima, la misma llega a valores de casi 2 [mm] por día entre noviembre y marzo, que constituye un déficit del CFSR en relación al CPC. La comparación entre ciclos anuales medios en ambas zonas, revela que entre abril y agosto el ajuste entre el reanálisis y los datos del CPC es muy bueno, pero durante el resto del año la calidad del ajuste se reduce; en particular para la zona 2 donde además el CFSR se comporta por defecto. La situación temporal descrita establece que la precipitación obtenida del reanálisis muestra una mejor representación de los datos de CPC en períodos donde las lluvias resultan escasas.

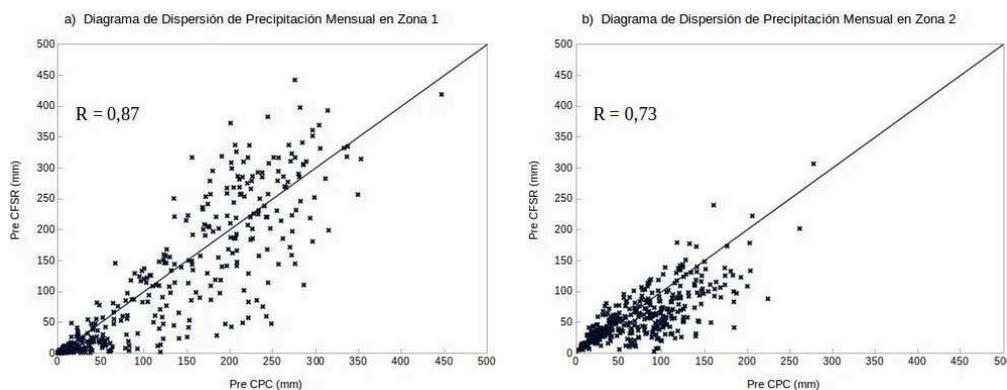


Figura 2.3: Diagrama de dispersión entre valores mensuales de Precipitación de CFSR y CPC, correspondiente al período 1980-2010. a) Correspondiente a la Zona 1 y b) a la Zona 2.

Los diagramas de dispersión de los valores mensuales de precipitación que muestra la figura 2.3 en ambas zonas, contribuye a reforzar lo establecido en la figura 2.2 respecto al grado de vinculación entre el reanálisis y los datos del análisis. Para la zona 1 el diagrama entre

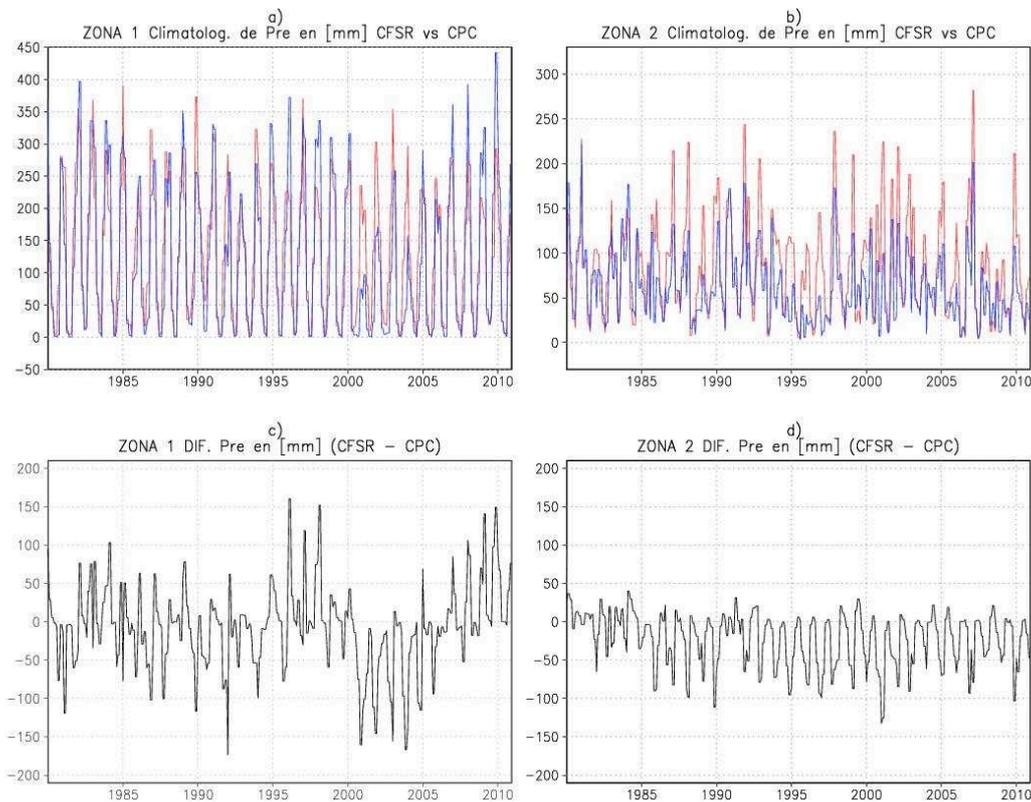


Figura 2.4: Climatología de Precipitación para el período 1980-2010 de CFSR (azul) y de CPC (rojo). a) Valores promedio para la zona 1, b) Idem para zona 2. Diferencias entre climatologías de CFSR y CPC, c) en zona 1 y d) en zona 2.

CFSR y CPC muestra una correlación más alta ($r = 0,87$) que en la zona 2 donde ($r = 0,73$), también destaca que los valores mensuales de CFSR son menores que los de CPC en particular para la zona 2. Esto es evidente en la cantidad de puntos que se encuentran por debajo de la recta de referencia de pendiente 1, además los valores se encuentran más agrupados reflejando un ciclo anual más uniforme para la zona 2 en relación con zona 1 que presenta una mayor dispersión. Las series de tiempo de precipitación en ambas zonas en figuras 2.4a) y b) muestran comportamientos que reflejan los ciclos anuales medios vistos en la figura 2.2. Un fuerte ciclo anual se aprecia en la figura 2.4a) con valores máximos mensuales durante la estación cálida llegando hasta los 450 [mm] y nula precipitación en invierno, en contraposición a la zona 2 donde el ciclo anual no es tan marcado como en zona 1 con valores mensuales que rara vez son nulos y menor amplitud entre los valores máximos y mínimos. La serie de tiempo del reanálisis en azul constituye un mejor ajuste sobre los datos del CPC, que se muestran en rojo, en zona 1. Además donde el ciclo no es tan marcado el ajuste desmejora, visualmente se aprecia en la figura 2.4b). Las diferencias entre series de precipitación de CFSR y CPC para cada zona se muestran en las figuras 2.4c) y d). Se aprecia claramente que en zona 1 las diferencias son alternadas desde 1980 hasta 1995 sin períodos preferenciales, luego existe un período donde el reanálisis sobreestima a los datos de CPC, que llega hasta el año 2001 y que se repite nuevamente a partir de 2006; entre medio de estos dos períodos se da el proceso inverso. Por otro lado en figura 2.4d) el reanálisis subestima al CPC, las diferencias son mayormente negativas y consistentes

durante casi los 31 años de evaluación llegando un déficit máximo de 130 [mm] en 2001.

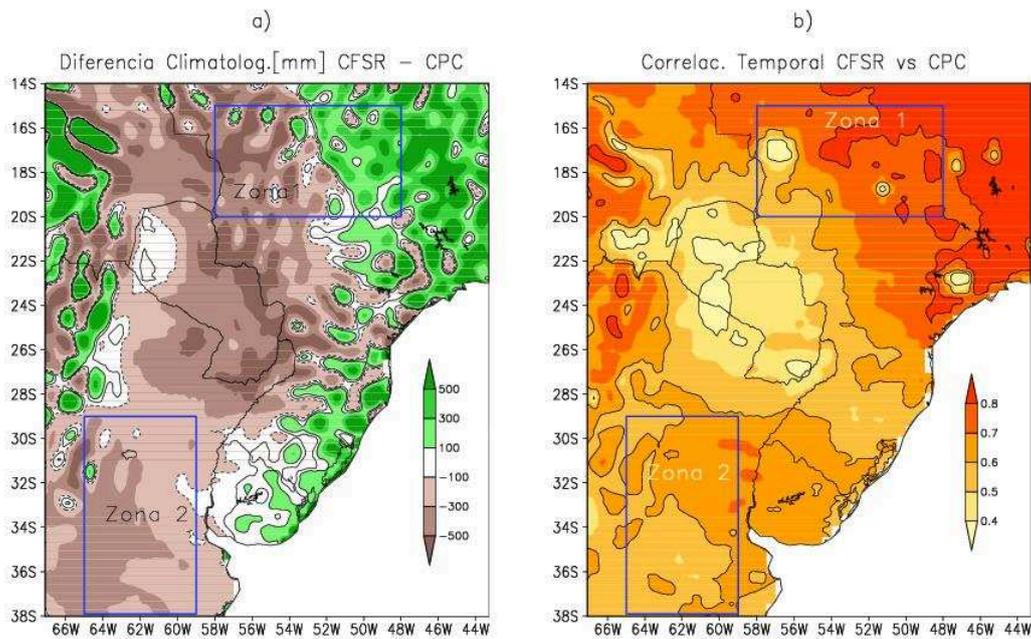


Figura 2.5: a) Diferencias entre climatologías de precipitación de CFSR y de CPC expresadas en [mm]. b) Correlación temporal de datos mensuales de precipitación de CFSR y de CPC. Ambos análisis realizados durante el período 1980-2010

Posteriormente se estudiaron las variaciones espaciales y se evaluaron las diferencias entre las climatologías de precipitación de CFSR y de CPC durante el período 1980-2010, así como también las regiones donde existe un mejor ajuste entre los valores de precipitación mensual de cada producto a través de la correlación temporal. Los resultados obtenidos se muestran en las figuras 2.5a) y b). El estudio previo implica la realización de un re-grillado ya que como se indicó previamente los datos de CFSR poseen una resolución horizontal de ≈ 38 km ($0,3^\circ$) mientras que los datos de CPC se encuentran grillados a $0,5^\circ$ de resolución horizontal; y ambas fuentes de datos deben tener la misma resolución para poder ser analizados conjuntamente. El re-grillado se generó mediante interpolación utilizando un re-mapeo conservativo de primer orden (a través de la aplicación `cdo/remapcon`) con lo cual se logró redefinir las grillas de los datos de ambas fuentes, con una resolución regular de $0,125^\circ$ en ambos archivos; se adoptó esa resolución debido a que posteriormente se empleará esta misma resolución para durante la implementación del modelo de superficie en la región de la cuenca del Plata durante el capítulo 3.

Los valores positivos marcados en color verde en diferentes intensidades a partir del valor 100 [mm] en la figura 2.5a), identifican a las regiones donde la variable precipitación del reanálisis sobreestima a los datos de precipitación del análisis, esto es resulta particularmente evidente en las zonas donde existe una elevación importante de la topografía del lugar, aunque no es excluyente. Valores de diferencias de 500 [mm] en colores de verde muy intenso se aprecian en las regiones del noroeste Argentino y también en la región del Altiplano Boliviano. Pero también ocurre en la zona costera Atlántica del sur de Brasil y parte de Uruguay de topografía

suave o plana, con verdes intensos que indican precipitación del CFSR por sobre CPC del orden de 300 [mm]. Existe visualmente una mayor cantidad de regiones donde las diferencias positivas se concentran en discontinuidades cerradas o núcleos, que probablemente sea debido a la interpolación y al mayor nivel de detalle de la información por la nueva resolución. Existe también sobreestimación del CFSR en la región central de Brasil con diferencias de 500 [mm] y disminuyendo hacia el oeste. En contraposición, gran parte de esta región de Sudamérica, que abarca desde el este de Bolivia, parte de Brasil y norte de Paraguay hasta el centro-norte de la provincia de Buenos Aires se encuentran bajo tonalidades marrones de diferentes intensidades que refieren a valores de la climatología de precipitación del reanálisis por debajo de la de CPC, con diferencias de -100 [mm] hasta -500 [mm]. Prácticamente la totalidad de la región central de Argentina, incluyendo zona 2, muestra un déficit del CFSR entre 100 [mm] y 300 [mm], más aún regiones al oeste de la misma muestran un déficit mayor, como el oeste de Buenos Aires, noreste de La Pampa y sur de Córdoba con valores entre -300 [mm] y -500 [mm]. Déficit de más de 500 [mm] se ven en parte de Formosa y zona limítrofe entre Paraguay y Argentina delineada por el río Paraná, así como en la frontera entre Paraguay y Brasil. Las menores diferencias se muestran en color blanco para el rango entre -100 [mm] y 100 [mm], como por ejemplo pequeñas regiones en el norte de Paraguay y noroeste de Argentina, no obstante en Uruguay este rango de variación cubre gran parte de ese país.

Estas diferencias encontradas en la figura 2.5a), si bien son evidentes y permiten dar cuenta de las regiones donde hay sobreestimación por parte del CFSR así como también las regiones donde se ven déficits del reanálisis, las diferencias exhibidas en la figura 2.5a) son valores medios y no reflejan demasiado a cerca de cómo es la vinculación espacial de la precipitación de ambas fuentes de datos durante el tiempo de análisis. Para mejorar el entendimiento y ver espacialmente cuales son las regiones donde existe un mejor ajuste, se determinó la correlación temporal para cada punto de grilla para el período de ventana, cuyos resultados se muestran en la figura 2.5b). La región que presenta la mejor correlación la constituye la parte centro-este de Brasil con valores de $(r) = 0,8$, incluyendo la porción noreste de la zona 1; lo que resulta esperable porque representa la región del SAMS en la cual el ajuste es muy bueno. El mismo valor de correlación se obtuvo en la zona del Altiplano Boliviano y en pequeñas regiones del noroeste Argentino. Valores de coeficientes de $(r) = 0,7$ rodean a las regiones de mayor correlación mencionadas. Existen valores de $(r) = 0,6$ en todo Uruguay y gran parte de la región central de Argentina que abarca el centro-este de Córdoba, gran parte de Santa Fe, la totalidad de Entre Ríos, parte de Buenos Aires y Corrientes, que representa el centro-norte de la zona 2. Por otro lado, valores de correlación más bajos se observan sobre Paraguay con $(r) = 0,5$ y menores, así como también en parte de Formosa. En relación con la figura 2.5a) las zonas identificadas con verde intenso que representan exceso de CFSR, son las que tienen valores de correlación más elevados, excepto la región costera del sur de Brasil y Uruguay donde la correlación es del orden de $(r) = 0,5$. En sentido opuesto, en las regiones donde el déficit del CFSR es mayor, de color marrón intenso, existen correlaciones que en general resultan bajas, como ocurre en gran parte de Paraguay.

Las contribuciones estacionales a las diferencias entre climatologías mostradas en la figura 2.5a) se presentan en las figuras 2.6a-d), en la misma se observan diferencias en cada una de las estaciones entre las climatologías de precipitación de las dos fuentes evaluadas, y se aprecia cuáles de ellas presentan mayores diferencias y en cuales esa diferencia es menor. Los valores de cada estación fueron determinados como diferencias entre valores estacionales medios de cada fuente en el período 1980-2010. Se destacan las estaciones de verano, otoño y primavera como las que presentan mayor variación entre ambas fuentes de datos, tanto en forma cualitativa como cuantitativa, en sentido opuesto durante los meses de invierno las diferencias son mínimas prácticamente en toda la región del SESA.

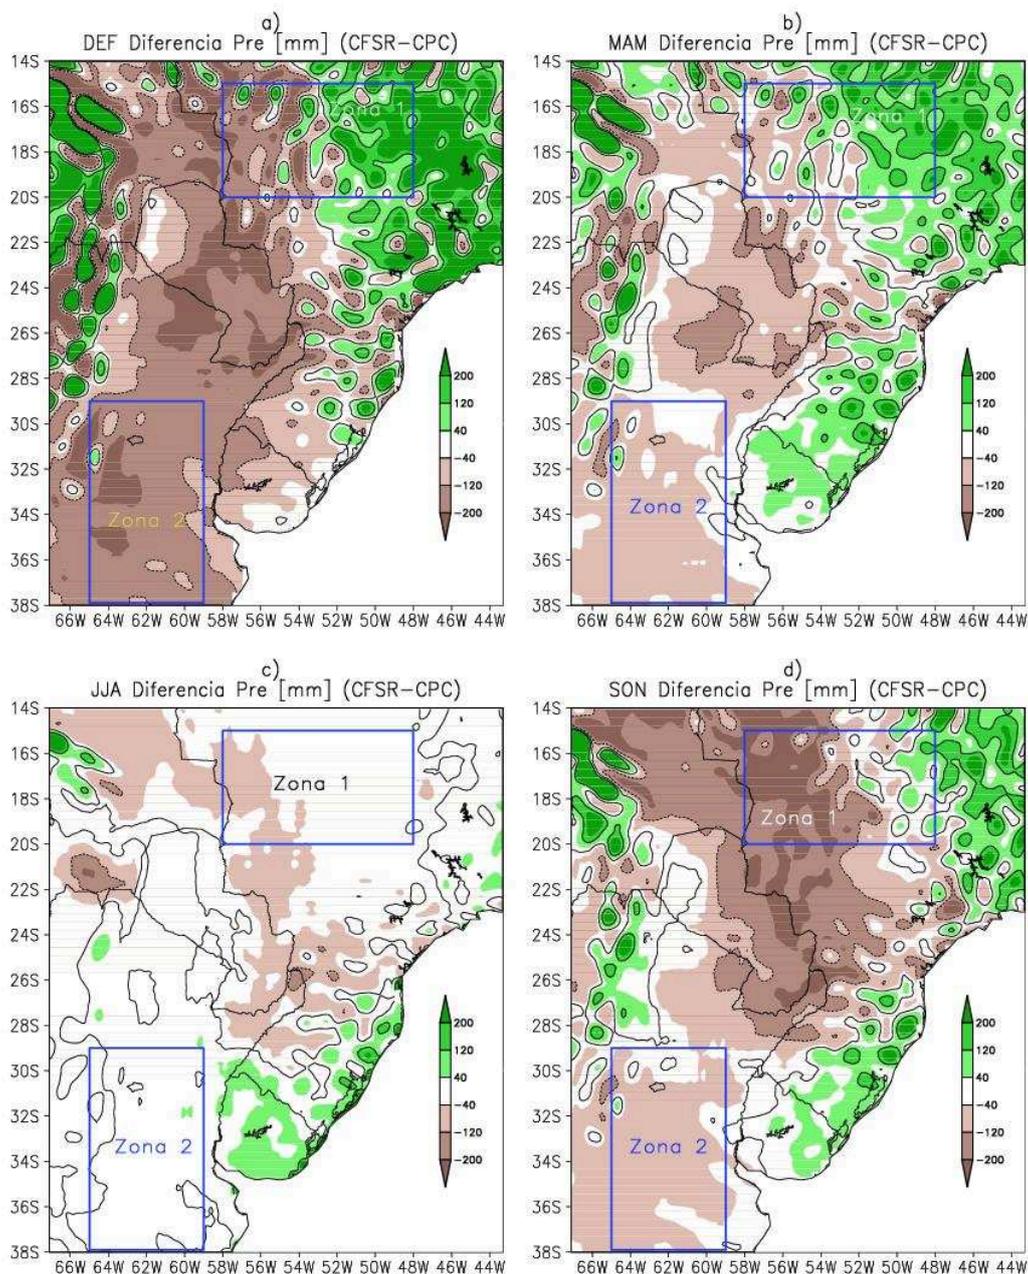


Figura 2.6: Diferencias de precipitación media estacional en [mm] entre CFSR y CPC para el período 1980-2010. a) DEF, b) MAM, c) JJA, d) SON

Concretamente en las figs. 2.6a), b) y d) se observa el mismo patrón de diferencias que en

la figura 2.5a), es decir precipitación de CFSR por exceso en regiones de mayor topografía y por defecto en la región central. En particular la zona 1 presenta en su parte este valores del reanálisis por exceso, siendo más notorio en verano, disminuyendo el exceso hacia el otoño, y en primavera solo una pequeña porción al este de la misma presenta valores de CFSR excedentes, aunque del orden de 40 [mm]. Un comportamiento opuesto se registra hacia el oeste donde los valores de CFSR son por defecto, es más notorio en primavera y verano (figs. 2.6d) y a)) con valores de 120 [mm], mientras que en otoño la diferencia es de 40 [mm]. Por otro lado, zona 2 presenta valores de precipitación del reanálisis deficitarios en las tres estaciones mencionadas anteriormente, siendo mayor el déficit en los meses de verano llegando a superar los 120 [mm], mientras que en otoño y primavera, en las figs. 2.6b) y d), el patrón es similar pero las diferencias son del orden de 40 [mm]. La estación invernal en la figura 2.6c) muestra una distribución diferente al resto de las estaciones con un predominio de diferencias entre CFSR y CPC bajas, en consecuencia gran parte del mapa se encuentra cubierto por color blanco. La región que abarca Uruguay y la costa sur de Brasil presentan valores por exceso del reanálisis superiores a 40 [mm] y también una pequeña parte del Altiplano Boliviano con diferencias algo mayores. Por otro lado las regiones deficitarias de CFSR abarcan centro-sur de Brasil, este de Bolivia, y la región limítrofe entre Argentina, Paraguay y Brasil con valores cercanos a 40 [mm], también existe una región deficitaria de más de 120 [mm] entre Argentina y Bolivia. El resto constituyen una gran región que presenta diferencias mínimas entre las fuentes, -40 [mm] y 40 [mm], entre la que se encuentra la zona 2 y casi toda la zona 1.

Correlación Estacional [CFSR vs CPC]	Zona 1	Zona 2
DEF	0,62	0,64
MAM	0,75	0,65
JJA	0,64	0,69
SON	0,61	0,63

Cuadro 2.1: Correlación temporal entre datos de precipitación estacional de CFSR y de CPC para el período 1980-2010, correspondiente a la zona 1 y zona 2.

El Verano es la estación que presenta las mayores variaciones cuantitativas con relación al resto de las estaciones, tanto en exceso como en déficit. Esto indica que esta estación es la que mayor contribución aporta a las diferencias entre climatologías de la figura 2.5a), en el caso opuesto se encuentra la estación invernal, mientras que tanto primavera como otoño se encuentran en una situación intermedia.

La tabla 1 muestra valores de correlación temporal para cada estación entre precipitación media estacional de CFSR y de CPC, tanto en zona 1 como en zona 2. Esta zona se destaca por tener en general coeficientes de correlación estacionales levemente mayores que zona 1, con excepción de la estación de otoño donde zona 1 mejora a zona 2. De todas las estaciones, en invierno es cuando se registra la mejor correlación para zona 2 con un valor de $(r) = 0,69$, mientras que para la zona 1 lo mismo ocurre en otoño con $(r) = 0,75$; el resto de las estaciones presentan coeficientes del orden de $(r) = 0,6$. Es interesante analizar el comportamiento que presenta

zona 1 cuando se evaluaron las diferencias entre la precipitación del reanálisis y la de CPC (ver figs. 2.5 y 2.6), ya que en la misma se presentan diferencias por excesos en su parte este y por defecto en la oeste, con una división en diagonal noroeste-sureste aproximadamente sobre la mitad de la misma, figura 2.5a). Esta diferencia también se detecta en la correlación temporal de la figura 2.5b) mostrando valores de $(r) = 0,7-0,8$ hacia la derecha de la diagonal reduciendo los valores de la correlación hacia la izquierda con valores de $(r) = 0,6$ y menores. Este patrón de diferencias se sostiene también en el análisis estacional, ver figs. 2.6a), b) y d). En oposición, zona 2 presenta cualitativamente un comportamiento más uniforme y con tendencia al déficit de CFSR, como se aprecia en las figs 2.6a)-d) y también en figura 2.5a).

2.2. Índice de Monitoreo de Precipitación.

Ciertas variables de superficie necesitan un seguimiento y monitoreo de su comportamiento y evolución (McKee et al., 1995), esta actividad se considera una práctica que resulta útil para la prevención de los eventos extremos secos. Estos autores también establecen que el monitoreo debe considerar el estado de la precipitación y de los distintos niveles que contengan el agua en superficie, como por ejemplo la humedad del suelo, la escorrentía, entre otros componentes del ciclo hidrológico; al mismo tiempo también se debe considerar la demanda de agua y los posibles impactos que pudiera ocasionar la sequía.

El monitoreo de eventos secos se realiza a través de la evaluación y el comportamiento de un índice de precipitación, el Índice de Precipitación Estandarizado (de aquí en adelante SPI por su sigla en inglés) es uno de los más usados a nivel local, regional y global para el monitoreo de eventos extremos. Este índice ha sido creado para dar respuestas a las limitaciones de otro indicador que hasta entonces era de uso amplio en Estados Unidos para monitorear eventos de sequía (Hayes et al., 1999), el indicador de sequía de Palmer (PDSI, Palmer, 1965). Si bien ambos indicadores son estandarizados y permiten realizar comparaciones en diferentes regiones, el PDSI utiliza una mayor cantidad de variables que el SPI para su determinación (Heim, 2002). En otro sentido Byun y Kim (2010) compararon el comportamiento del SPI, a distintas escalas de tiempo, con el Índice de Sequía Efectivo (Byun y Wilhite, 1999) (EDI, por su siglas en inglés) en Corea del Sur, destacando particularmente las ventajas de este último para detectar sequías de corta duración, producto de utilizar datos de precipitación a paso diario, en relación a la detección de las mismas con SPI; la desventaja del EDI radica en la dificultad de contar con datos diarios para su estimación, lo que representa una limitación para un uso más amplio y a nivel operacional (Morid et al., 2006). En virtud de todo lo expresado, además el SPI ha sido reconocido particularmente como el indicador de uso global para establecer, detectar y monitorear sequías de acuerdo a *The Lincoln Declaration on Drought Indices* (Hayes et al., 2011). Concretamente el índice representa la diferencia estandarizada entre la precipitación y su valor medio (McKee et al., 1993), además constituye un indicador ampliamente usado por su simplicidad de cálculo (Redmond, 2002) y por su naturaleza estandarizada. Usualmente limitado

al ajuste de una función de distribución de probabilidad paramétrica, generalmente *Gamma* o *LogNormal*, pero más recientemente también asociado a funciones de probabilidad empírica (Farahmand y AghaKouchak, 2015) lo que además le brinda la posibilidad de independizar el comportamiento de la variable estandarizada a una función teórica de ajuste.

2.2.1. Metodología. Construcción del Índice de Precipitación Estandarizado [SPI] no paramétrico.

Una de las principales ventajas que presenta el SPI sobre el resto de los indicadores es que se puede usar a distintas escalas temporales, en este sentido para esta parte del trabajo se propone la construcción y el uso de SPI a través de escalas de tiempo de 3 y 6 meses. Se estimará su valor utilizando tanto la base de datos de precipitación mensual del reanálisis como también la base de precipitación del CPC, mediante la metodología no paramétrica (Farahmand y AghaKouchak, 2015) que asocia su determinación a una probabilidad de ocurrencia empírica (Gringorten, 1963). Posteriormente, con el uso de estos indicadores y sobre las escalas de tiempo mencionadas, se visualiza el comportamiento de cada índice a fin de detectar períodos de déficits que represente la ocurrencia de un evento seco. El concepto empírico empleado en la estimación del indicador SPI se independiza de la función de distribución teórica paramétrica asociada a la variable precipitación. Por ejemplo la función *Gamma* (McKee et al., 1993) fue usada para la construcción de SPI en el Sudeste de Sudamérica por diversos autores, entre ellos Krepper y Zucarelli (2010), pero también más cerca en el tiempo Penalba y Rivera (2015). Por otro lado también se han utilizado las funciones *LogNormal* o *Pearson III* para su construcción y evaluación (Guttman, 1999; Quiring, 2009). En este sentido Blain (2010) evaluó el SPI en el estado de San Pablo, Brasil, utilizando las funciones teóricas *Gamma* y *Pearson III*, y determinó que la distribución *Pearson III* parece representar mejor el comportamiento de las series de precipitación prolongadas en el tiempo. Para reducir una de las limitaciones mencionadas en Lloyd-Hughes y Saunders (2002) relacionada al uso de la función de probabilidad teórica asociada a la variable, en este trabajo se propone la construcción de SPI utilizando un esquema basado en la función de probabilidad empírica (Gringorten, 1963), para generar el índice estandarizado no paramétrico. Su metodología resulta, por otro lado, válida para analizar eventos extremos basándose en el estado de otras variables además de la precipitación, como humedad del suelo, escorrentía, entre otras (Hao et al., 2014; Farahmand y AghaKouchak, 2015).

El indicador $SPI_i(t)$ es el índice estandarizado de precipitación para una escala temporal de cálculo i cualquiera que esta sea, usualmente $i = 1, 3, 6, 9, 12, \dots, N$ meses, que corresponde a un mes calendario de un año cualquiera, $t = 1, 2, \dots, 12$. La forma de estimar SPI para $i = 2$ meses por ejemplo es la siguiente, sea P_2 la series de precipitación acumulada de 2 meses para un mes t , $P_2(t)$, desde el mes $t - 1$ hasta el mes t . Se ajusta luego la serie completa P_2 a una función de probabilidad empírica $p(x_i)$, ver fórmula (2.1) y figura 2.7a). Posteriormente se estandariza la distribución aplicando la inversa de la función de distribución normal estandarizada, SI ,

ver fórmula (2.2) y figura 2.7b), de valor medio 0 y desvío estándar 1 (McKee et al., 1993; Mishra et al., 2009). Gráficamente y continuando con el ejemplo, el valor de SPI2 para el mes (t) se genera ingresando al panel de la figura 2.7a) con el valor de precipitación P_2 del mes (t) que tiene asociada a su valor una probabilidad empírica de ocurrencia $p(x_i)$, y con ese mismo valor de probabilidad se ingresa luego al panel de la figura 2.7b) y se obtiene un valor de SPI2 que equivale a la inversa de la función normal estandarizada aplicada a la probabilidad de ocurrencia de $P_2(t)$. Debido a su naturaleza estandarizada los valores de SPI de diferentes locaciones pueden compararse entre sí (Keyantash y Dracup, 2002), ya que la estandarización asegura que la frecuencia de ocurrencia de eventos extremos secos, entre locaciones diferentes, asociados a una misma escala temporal, sean consistente entre sí (Lloyd-Hughes y Saunders, 2002). De acuerdo al esquema de construcción del indicador, la probabilidad empírica utilizada en Gringorten (1963) se obtiene de formula (2.1).

$$p(x_i) = \frac{i - 0,44}{n + 0,12} \quad (2.1)$$

$$SI = \phi^{-1}(p) \quad (2.2)$$

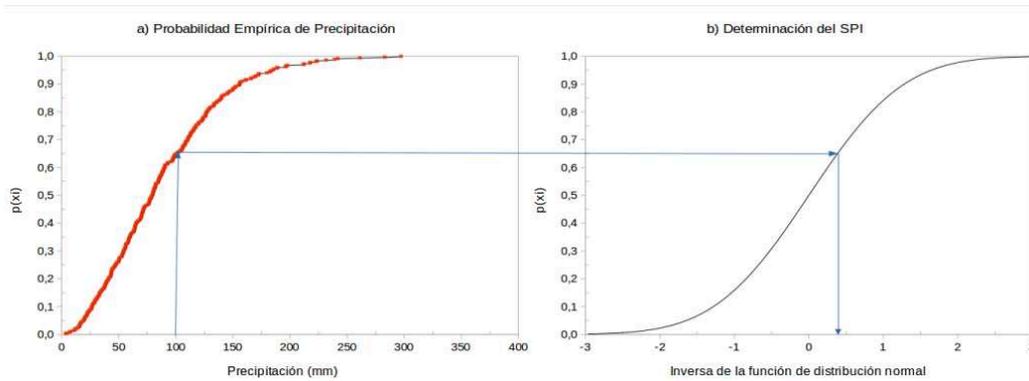


Figura 2.7: a) Función de probabilidad empírica asociada a la precipitación. b) Inversa de la función de distribución estandarizada, para los valores de probabilidad asociados a la precipitación.

Donde $p(x_i)$ es la probabilidad empírica correspondiente, n es el tamaño de la muestra, e i es el rango de valores de precipitación distintos de cero desde el menor (Farahmand y AghaKouchak, 2015). Al usar este valor de probabilidad, no se necesita ajustar una función de distribución teórica para la variable analizada y su gráfica se aprecia en la figura 2.7a). Los valores de $p(x_i)$ se estandarizan mediante la aplicación de la inversa de función de distribución normal estandarizada en fórmula (2.2). El valor de SI obtenido corresponde al índice estandarizado, y usando esta metodología se estimaron los indicadores mensuales del período de ventana 1980-2010 para las dos fuentes de datos de precipitación analizadas. Posteriormente en este trabajo se utiliza la misma metodología para obtener los indicadores estandarizados de las variables que se analizan en los capítulos 4 y 5.

2.2.2. Evaluación del SPI.

Utilizando los datos de precipitación de ambas fuentes, se construyeron los indicadores SPI, en toda la región del SESA para el período de tiempo que comienza en 1980 y llega hasta 2010 totalizando 372 meses. Se eligió evaluar SPI con escalas de tiempo de 3 y 6 meses (SPI3 y SPI6) que representan la duración más probable de eventos secos en esta región de Sudamérica; en concordancia con lo establecido en Mo y Berbery (2011), donde se refiere a la duración de los eventos secos y su posibilidad de recuperación de acuerdo con el ciclo anual. La estimación de los indicadores se realizó a fin de evaluar la metodología de construcción y también verificar si las diferencias encontradas entre la precipitación de CFSR y la de CPC, en el punto anterior de este mismo capítulo, se mantienen o se modifican cuando se las evalúa a través del SPI. En un primer paso se construyeron series de tiempo de cada indicador para zonas 1 y 2, como se muestra en las figuras 2.8 y 2.9 respectivamente. Las series determinadas en cada zona constituyen valores de SPI promediados arealmente en cada una de las zonas analizadas. El algoritmo utilizado en la determinación del promedio areal tiene en cuenta la ponderación del área en función del cambio de latitud que se registra en cada zona; de manera similar se procedió en la determinación de las series de tiempo de precipitación en las figuras 2.4a) y b). Los paneles a) y b) de la figura 2.8 refieren a series de tiempo de SPI3 y SPI6 promediados arealmente en zona 1, idénticamente en la figura 2.9 se muestra para zona 2; además los paneles c) y d) tanto de la figura 2.8 como de la figura 2.9, representan las diferencias encontradas entre las series de tiempo de los indicadores SPI3 y SPI6 respectivamente, determinados a través de ambas fuentes.

Los indicadores de escala de tiempo 3 meses muestran un comportamiento de las series con mayor fluctuación que las mismas de SPI6, esto se debe a que al incrementar la escala temporal de cálculo del índice se genera un suavizado del mismo ocasionado por la acumulación de la precipitación a lo largo del tiempo de escala usado en el cálculo. Esta característica ha permitido el uso de distintas escalas temporales y vincularlas con tipos de sequías diferentes a través de SPI; por ejemplo en Lloyd-Hughes y Saunders (2002) se menciona que menores escalas temporales son usadas para caracterizar sequías agrológicas, donde existe un déficit de humedad del suelo, mientras que escalas de tiempo mayores se relacionan con sequías hidrológicas.

La serie de tiempo de SPI3 basada en datos de CFSR y la serie del mismo indicador basada en datos de CPC no muestran un comportamiento muy asociado entre sí en zona 1. Las diferencias entre ambas series se ven en la serie de la figura 2.8c), que muestra valores que alternan entre 2 y -2 desde 1980 hasta 1995. Luego a partir de 1996 comienza un período de continuo predominio de diferencias positivas, es decir valores de SPI basado en CFSR mayores que el mismo indicador construido en base a datos de CPC, ese comportamiento se extiende hasta aproximadamente el año 2001. A partir de ahí continúa un período de déficit que llega hasta 2007, cuando comienza un nuevo período de valores positivos que se mantiene hasta 2010. Este mismo comportamiento se verifica con algo más de claridad en el indicador SPI6 en las figuras 2.8b) y d) debido

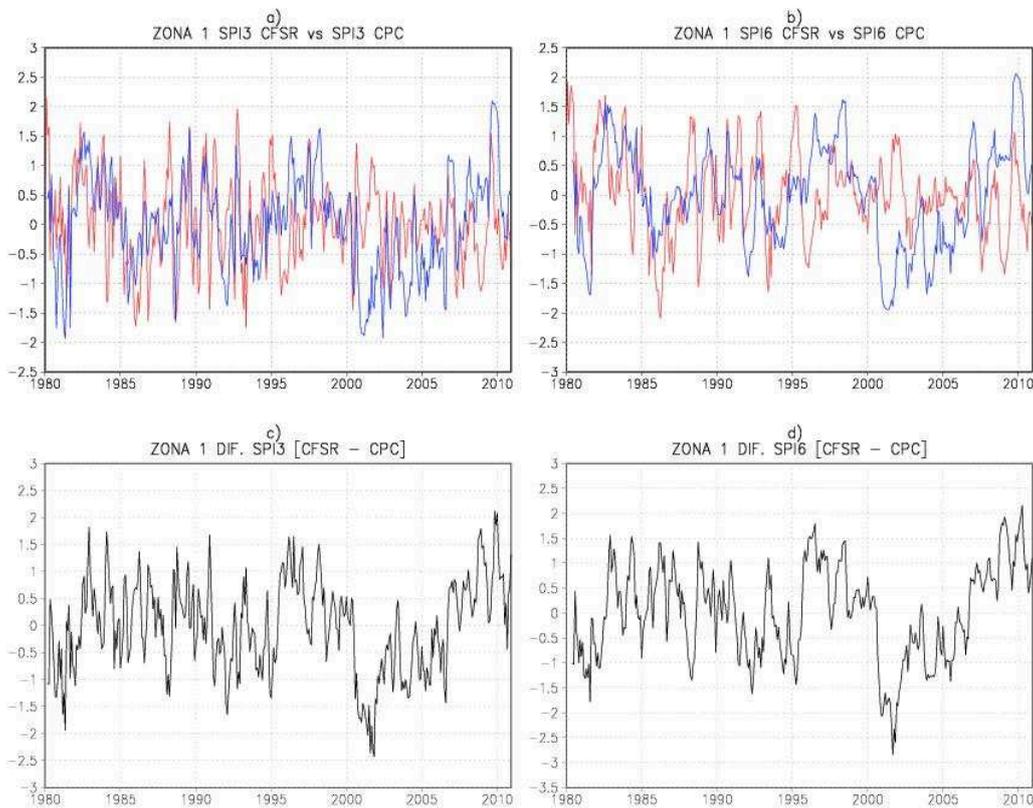


Figura 2.8: a) Series temporales medias areales de SPI3 para la zona 1 referente al período 1980-2010, basadas en datos mensuales de precipitación de CFSR (azul) y basadas en datos de CPC (rojo). b) Ídem para SPI6. c) Diferencias en la zona 1 entre series temporales de SPI3 [CFSR – CPC], y d) Ídem para SPI6.

a la mayor escala de tiempo usada en la construcción del indicador. Otra forma de analizar la vinculación entre los indicadores basados en CFSR y en CPC, es mediante el gráfico de dispersión de las figuras 2.10a) y b), en ambos gráficos se ratifica el bajo ajuste que presenta tanto SPI3 como en SPI6 en la zona 1, con coeficientes de correlación $(r) = 0,39$ y $(r) = 0,27$ respectivamente, mostrando valores sorprendentemente bajos. Si bien las diferencias entre series temporales de precipitación de ambas fuentes (ver figura 2.4c)) siguen patrones similares a las diferencias encontradas en las series de SPI en figura 2.8c) y d), donde coinciden mayormente los períodos de exceso y déficit de CFSR. Existe, en contraposición, una marcada disminución del coeficiente de correlación, pasando de $(r) = 0,87$ como se muestra en figura 2.3a) a valores poco promisorios $(r) = 0,39$ para SPI3 y $(r) = 0,27$ para SPI6 en zona 1, ver figuras 2.10a) y b). Esto indica que evaluar las fuentes de precipitación de CFSR y CPC, mediante la correlación de cada indicador, desmejora los valores de correlación obtenidos de la evaluación directa de la variable de precipitación en la zona 1, como se puede ver en las figs. 2.4a) para precipitación, y 2.10a) y b) para los indicadores. Sin embargo el patrón de diferencias obtenido de las figuras 2.4c), y 2.8c) y d) resulta consistente.

De forma puesta, a lo que ocurre con zona 1, en zona 2 el comportamiento mostrado en las figuras 2.9a) y 2.9b) permite definir una mejor vinculación entre la precipitación de CFSR y de CPC a través de los indicadores SPI3 y SPI6 respectivamente. El ajuste es muy bueno en

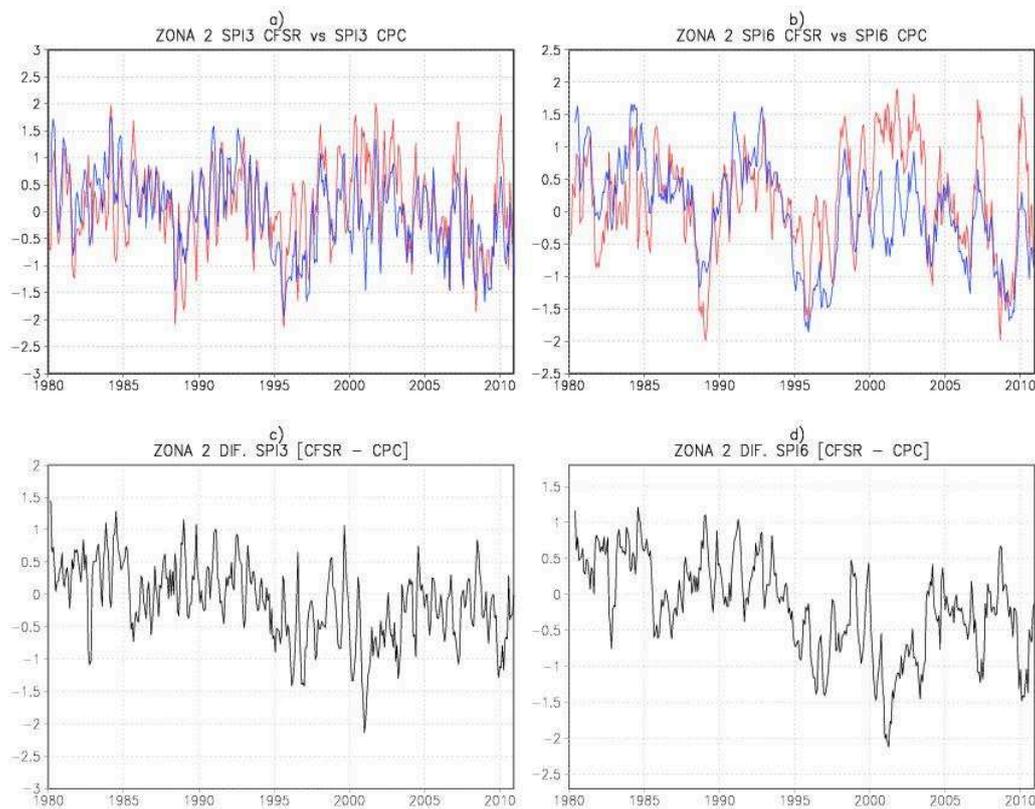


Figura 2.9: Ídem figura 2.8 pero referido a zona 2.

particular para el período 1980-1995 y también luego de 2005 en ambos indicadores. Durante el período intermedio el grado de vinculación parece disminuir, y al mismo tiempo durante este intervalo la serie de las diferencias en cada SPI comienza a revelar un comportamiento sostenido de CFSR por defecto en relación a CPC que parece recuperarse luego de 2005, como se ve en las figuras 2.9c) y d).

Esa mejora del ajuste en zona 2 se verifica con los valores de correlación obtenidos a por ambos índices en dicha zona. Los coeficientes muestran valores de $(r) = 0,71$ para SPI3 y $(r) = 0,65$ para SPI6, en las figuras 2.10c) y d), muy por encima de los obtenidos para zona 1, que eran de $(r) = 0,39$ y $(r) = 0,27$ respectivamente, y mas cercana a la correlación mostrada por los datos de precipitación de CFSR y CPC en zona 2 con $(r) = 0,73$, ver figura 2.3b). Asimismo según se observa en la figura 2.5a) la zona 2 posee un comportamiento de diferencias que se muestra relativamente uniforme y por defecto de CFSR, cuando se evalúan climatologías de precipitación de CFSR y CPC. Este grado de uniformidad de las diferencia parece sostenerse también estacionalmente como se destaca en las figuras 2.6a)-d), con muy poca variación. Mientras que por el contrario la zona 1 se encuentra caracterizada por tener un comportamiento más bien heterogéneo presentando una región deficitaria de CFSR en la parte oeste y una zona opuesta donde los valores de CFSR son por exceso, al este de la misma. Este grado de heterogeneidad de las diferencias encontradas en zona 1, ver figuras 2.5a) y 2.6a)-d), puede ser responsable de que el ajuste en esta zona sea más pobre que en zona 2 donde las diferencias son más uniformes.

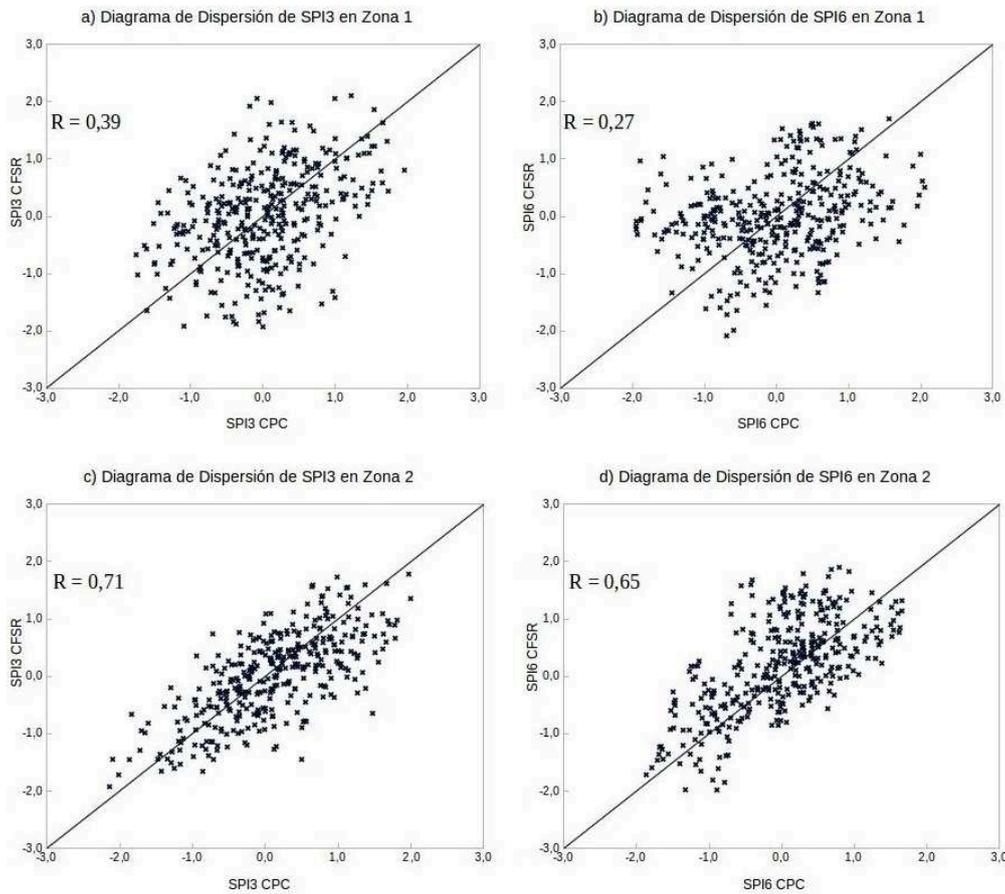


Figura 2.10: Diagramas de dispersión para el período 1980-2010 a) entre SPI3 (CFSR) y SPI3 (CPC) para la zona 1. b) Idem para SPI6. c) entre SPI3 (CFSR) y SPI3 (CPC) para la zona 2. d) Idem para SPI6.

Para caracterizar espacialmente las regiones donde el comportamiento de los índices SPI contruidos, reviste mayor error, se estimó una medida de esta deficiencia a través del error cuadrático medio o *RMSE* (Root Mean Square Error, por su sigla en inglés), en cada punto de la grilla de datos abarcando el período completo de estudio, los valores se aprecian en las figuras 2.11a) y b). La determinación del error en cada punto analizado se obtuvo utilizando la expresión (2.3), donde y_i y \hat{y}_i son valores del índice basado en CPC y en CFSR respectivamente, evaluados al tiempo i , y n el tiempo total del análisis.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.3)$$

Valores de *RMSE* cercanos a 0 representan una situación óptima donde el reanálisis y el análisis presentan un error nulo y representa un ajuste perfecto, valores mayores a 0 indican una situación opuesta tanto mayor sea la magnitud del error, valores de *RMSE* menores o iguales a 0,5 veces el desvío estándar son considerados aceptables (Moriasi et al., 2007). Esta función objetivo al estar elevada al cuadrado es sensible a los valores atípicos o *outliers*, lo que

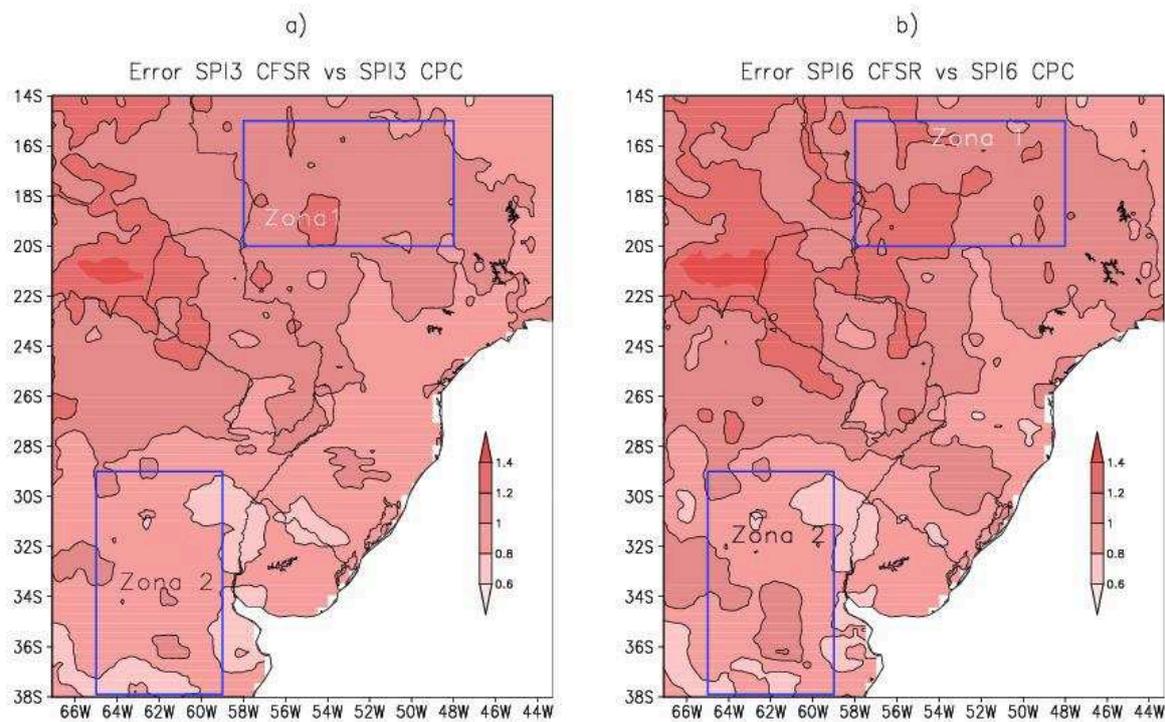


Figura 2.11: a) Error cuadrático medio ($RMSE$) para valores de SPI3 entre fuentes de CFSR y CPC para el período 1980-2010. b) Ídem para SPI6.

no ocurre en este caso por tratarse de valores de índices estandarizados. La distribución espacial del $RMSE$ muestra a la región norte de Argentina, en la frontera con Bolivia y Paraguay como la de mayor error del Sudeste de Sudamérica, con valores mayores a 1,2; en tanto que la magnitud del error disminuye espacialmente en dirección al este y hacia el sur. La región costera de Brasil presenta valores de 0,8, al igual que casi todo Uruguay y gran parte de la zona 2 en la que se obtienen valores de hasta 0,6 como se puede observar en la figura 2.11a). La distribución espacial del error para SPI6 resulta similar a la de SPI3, pero las regiones donde el error es menor se encuentran algo reducidas y por el contrario las de mayor error levemente aumentadas, respecto a SPI3. Esto se ve especialmente en zonas 1 y 2, donde al aumentar la escala de tiempo del indicador de 3 a 6, aumenta levemente la magnitud y la distribución del error.

2.3. Conclusión.

La evaluación de la climatología del reanálisis y del análisis permitió establecer que en la región central del Sudeste de Sudamérica, los datos medios de CFSR subestiman en general a los del CPC, con corrimiento de isolíneas hacia el este evidenciando la subestimación para esta región, en particular las líneas de 1000 [mm] y la de 500 [mm]. Por otro lado la mayor resolución en los datos originales del reanálisis genera discontinuidades donde se destaca la sobreestimación del CFSR por sobre CPC, y estos núcleos parecen ser más frecuentes en zonas de topografía elevada y divisoria de aguas de cuencas, generando una marcada variación espacial. Estas diferencias

entre las climatologías se cuantificaron, resultando variaciones negativas en la región central entre 100 [mm] y 300 [mm], así como en forma opuesta valores positivos que llegan hasta 500 [mm] de diferencia en la zona de Los Andes, indicando en esta región sobreestimación del reanálisis en las zonas de discontinuidades. Estacionalmente para los meses de verano se registran las mayores diferencias entre CFSR y CPC, tanto en exceso como en déficit de CFSR; mientras que invierno presenta diferencias mínimas prácticamente para todo el Sudeste de Sudamérica.

La distribución espacial de la correlación temporal entre climatologías genera valores más altos en las zonas donde el reanálisis sobreestima al análisis, con valores de (r) entre 0,7 y 0,8. En la región central donde CFSR subestima a CPC la correlación arroja valores menores (r) 0,4 y 0,5 excepto en la zona del litoral argentino donde los valores son algo más elevados. También en esta misma región el error cuadrático medio estimado a partir de SPI3 resulta menor que en el resto del SESA, mientras que para SPI6 el RMSE presenta valores algo más elevados.

Las zonas 1 y 2 muestran ciclos anuales medios diferentes entre sí. Zona 1 con un ciclo bien marcado con estación lluviosa en verano y seca en invierno y un coeficiente de correlación entre CFSR y CPC de $(r) = 0,95$. La distribución del ciclo anual medio en zona 2 se muestra más uniforme que en zona 1 y el ajuste disminuye a $(r) = 0,80$ entre las fuentes. Estacionalmente zona 2 presenta coeficientes de correlación medios areales más promisorios que zona 1 con un máximo de $(r) = 0,69$ en invierno; excepto en otoño cuando zona 1 tiene un coeficiente de $(r) = 0,75$. El resto de las estaciones con coeficientes cercanos a $(r) = 0,6$. Los valores mensuales de precipitación muestran un mejor ajuste en zona 1 que en zona 2, al igual que ocurre para el ciclo anual medio. Asimismo las diferencias entre precipitaciones de CFSR y CPC en zona 1 muestran diferencias alternantes, valores positivos para el período 1995-2001 y luego de 2006, mientras que las diferencias son negativas entre ambos períodos positivos. En tanto el comportamiento de las diferencias en zona 2 se mantiene por defecto de CFSR prácticamente en todo el período.

La series temporal de SPI3 presenta un comportamiento más fluctuante que la serie temporal de SPI6 que es más suavizada, debido a una mayor acumulación de la precipitación durante la escala temporal usada en la construcción del indicador. Las series de SPI3 en zona 1 no presentan buen ajuste entre las dos fuentes de precipitación con coeficiente de correlación $(r) = 0,39$. En contraposición a lo que ocurre con los valores mensuales de precipitación donde el ajuste en la misma zona es $(r) = 0,87$. No obstante las series temporales de diferencias entre fuentes, medidas con SPI3, son similares a las mismas medidas sobre la precipitación. La zona 2 muestra una vinculación más evidente entre indicadores de ambas fuentes a través del gráfico de dispersión, con $(r) = 0,71$ para SPI3 y $(r) = 0,65$ para SPI6. Una posibilidad del bajo valor de (r) entre CFSR y CPC en esta zona puede ser debido al patrón heterogéneo de las diferencias de ambas fuentes en zona 1.

Capítulo 3

Implementación del Modelo Hidrológico VIC en la cuenca del Plata.

Este capítulo se centra en dos partes, por un lado describe el funcionamiento del modelo de superficie que se implementará en la cuenca, haciendo un estudio en detalle de los procesos de transformación, de los parámetros de suelo y sus características como por ejemplo la sensibilidad de cada uno ante una variación de las condiciones impuestas; así como también determinar las variables de superficie que mayor impacto tienen ante la ocurrencia de un evento seco. Por otro lado se realiza la calibración de los parámetros y posterior validación para un período diferente de la etapa de calibración, en ambas etapas los datos usados para contrastar con las simulaciones fueron estimaciones satelitales de humedad del suelo. El ajuste en cada una de las etapas se realizó a través de diferentes funciones objetivos.

3.1. Descripción y características del Modelo Hidrológico VIC.

Para la concreción de los objetivos propuestos y determinar cuáles son las variables más sensibles a los eventos extremos, a los efectos de monitorear su comportamiento, un problema muy frecuente es la no disponibilidad de datos de las variables de superficie en calidad o en cantidad. Ante la ausencia de registros extensos de datos observados sobre las componentes del ciclo hidrológico, el uso de modelos hidrológicos de superficie (LSM por *Land Surface Model* de acuerdo con su sigla en inglés) puede suministrar un registro de datos consistentes que permitan evaluar a las componentes y su comportamiento. En Sheffield et al. (2006) se estableció que si el LSM tiene un sesgo mínimo y es forzado con datos meteorológicos precisos, el balance hidrológico simulado genera datos de las variables que pueden ser usadas en lugar de las observaciones para obtener una representación acorde del balance de agua.

En este trabajo el LSM usado para simular procesos de superficie es el modelo de Capacidad de Infiltración Variable (Liang et al., 1994; 1996a; 1996b), VIC por *Variable Infiltration Capacity* de acuerdo a su sigla en inglés. El mismo constituye un modelo hidrológico de superficie que utiliza un esquema que parametriza la variabilidad del suelo a través de una distribución espacial de probabilidad (Zhao et al., 1992; Liang et al., 1996b) mediante la cual se realiza la partición de la precipitación en infiltración y escurrimiento directo R (*runoff*) (Liang et al., 1994). La aplicación del modelo se puede realizar tanto escalas regionales como continentales con resoluciones espaciales que van desde los 2° de lat/lon de tamaño a los 1/8° (Cherkauer et al., 2003) y hasta 1/16° inclusive (Livneh et al., 2015). El modelo permite resolver los balances de agua y de energía a distintos pasos de tiempo, que van desde sub-diarios a diarios, a través de una interrelación entre las transferencias de atmósfera, vegetación, y suelo (Xie et al., 2004). Esta parametrización le permite simular procesos hidrometeorológicos de superficie (Shukla et al., 2013) y le brinda la capacidad para representar la variabilidad de la vegetación dentro de cada celda (Liang et al., 1994, 1996b; Nijssen et al., 2001). Presenta además un esquema de parametrización del suelo en profundidad en distintas capas, usualmente son 3 de espesores no fijos (VIC-3L) (Liang et al., 1996b, Xie et al., 2004); en esencia los espesores de cada capa de suelo constituyen parámetros de calibración del modelo, y el valor final del espesor de cada una se determina luego de este proceso. A diferencia de lo que ocurre por ejemplo en el modelo de superficie NOAH (Chen y Dudhia, 2001) donde las capas de suelo del modelo son 4 y donde el espesor de cada una de estas permanece invariable. Generalmente la primer capa es de poca profundidad y tiene una dinámica para poder representar la respuesta rápida de esta parte del suelo ante una precipitación (Liang et al., 1996b, Shukla et al., 2013). La capa intermedia representa variaciones más lentas de la humedad del suelo, y junto con la capa superior se encargan de generar el escurrimiento directo R, como se puede ver en la figura 3.1. Si el contenido volumétrico de humedad de la capa intermedia es mayor que el de la superior existe aporte de humedad por difusión hacia esta última (Maurer et al., 2001; Shukla et al., 2013). El flujo base o B (por *baseflow*) se obtiene del aporte de humedad del suelo de la capa inferior (Liang et al., 1996b, Shukla et al., 2013) que recibe humedad de la capa intermedia por gravedad y representa a las variaciones estacionales, ocasionalmente esta capa inferior puede sufrir variaciones de humedad ante una precipitación cuando las dos capas superiores se encuentran saturadas. Además, en cualquiera de las capas de suelo en donde existan raíces de cultivos o de cualquier tipo de vegetación en general, la humedad del suelo en esa capa puede ser extraída por evapotranspiración; en el esquema de la figura 3.1 se observa que la capa 3 tendrá una disminución de la humedad almacenada en la misma debido a la evapotranspiración. El mismo esquema de funcionamiento de la figura, muestra además el estudio de una celda cualquiera de la grilla, que se encuentra constituida por $N + 1$ tipos de cobertura, donde $n = 1, 2, \dots, N$ son las clases de vegetación y $N + 1$ es el tipo que le corresponde al suelo desnudo (Liang et al., 1994).

La simulación se realiza en cada celda de forma independiente sin considerar aportes de flujos horizontales (Gao et al., 2010), es decir son preponderantes los flujos verticales. Se observa en

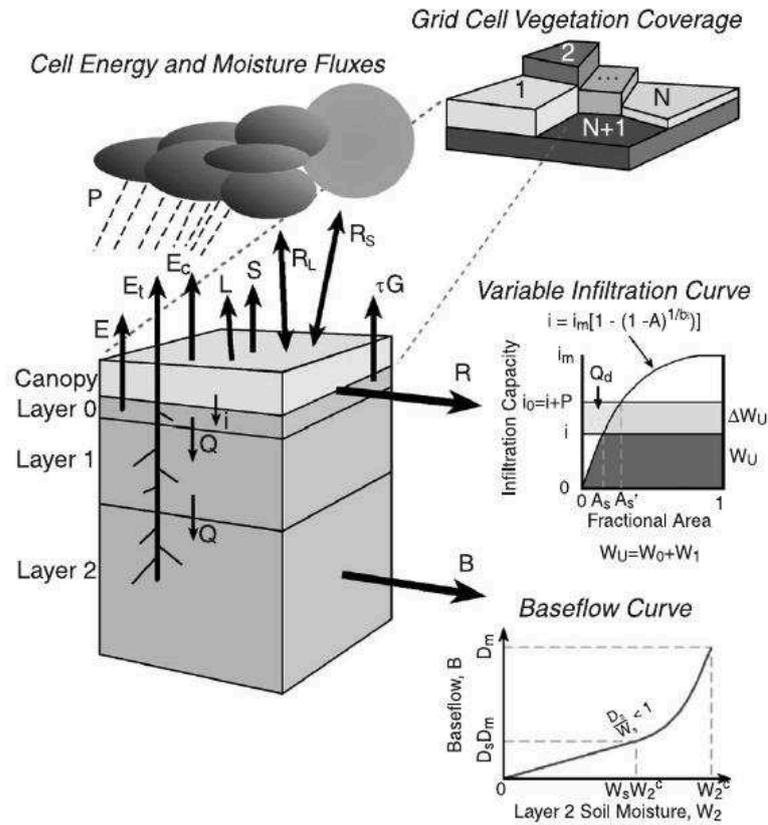


Figura 3.1: Esquema de parametrización de los procesos de superficie del modelo VIC (Cherkauer et al., 2003).

la figura que para un tipo de vegetación, de los N que se encuentran en la celda, cuáles son los intercambios de energía y cómo se distribuye en superficie el agua que precipita. Una función de distribución probabilística discretiza arealmente dentro de cada celda la cantidad de agua que se infiltra de la que queda en superficie (Zhao et al., 1992; Wood et al., 1992; 1997) y es la que se utiliza para generar el escurrimiento directo mediante la curva de Capacidad de Infiltración Variable. La evapotranspiración (E_t) se determina utilizando la ecuación de Penman-Monteith (Shuttleworth, 1993) en la que la evapotranspiración es función de la radiación neta, y el déficit de la presión de vapor. El valor total de Evapotranspiración para una celda, con N tipos de vegetación y suelo desnudo, se determina sumando los términos de evaporación del agua acumulada en suelo desnudo (E), evaporación del agua retenida por el canopeo (E_c), y la transpiración de las plantas (E_t); ponderando cada término por la fracción de área que ocupa en cada celda. Los valores de infiltración, de la distribución de la humedad del suelo, el drenaje entre las capas, el caudal directo y el flujo base se calculan para cada clase de cobertura del suelo en cada paso de tiempo. De manera similar ocurre para las variables de energía, calor latente (L), calor sensible (S), calor del suelo (G), radiación de onda larga (R_L) y de onda corta (R_S). Los valores totales de estas variables se obtienen sumando el aporte de cada tipo de cobertura y ponderando ese valor por la fracción que ocupa en la celda.

3.2. Aplicación en la región de estudio.

Algunos trabajos previos se han llevado a cabo en la cuenca del Plata, o en alguna de sus subcuencas, y que han sido sustentados en una implementación del modelo VIC para distintos fines. En Saurral et al. (2008) se investigaron los impactos que han tenido los cambios en el uso de suelo entre 1960 y 2000 en la cuenca del río Uruguay, a través de una simulación con el modelo VIC de la descarga a la salida de esa cuenca. En Su et al. (2008) han utilizado el modelo VIC para evaluar un producto satelital de precipitación, mediante la estimación de caudal en diversas subcuencas de la cuenca del Plata durante el período 1998-2006; también en Su y Lettenmaier (2009) se aplicó el modelo VIC durante el período 1979-1999 para la estimación del ciclo hidrológico en la cuenca del Plata. Mientras que en Grimson et al. (2013) utilizaron una particularidad que presenta el modelo VIC para simular humedales, y lo evaluaron en los Esteros del Iberá durante el período 1990-2011.

Para implementar el modelo superficial de capacidad de infiltración variable en la cuenca del Plata, se requiere la utilización de datos de forzantes meteorológicos y además de datos que caracterizan al sistema que constituyen los parámetros del modelo. Dentro de estos últimos se encuentran dos tipos de variables de superficie, las variables de vegetación y las variables del suelo. La cobertura de la vegetación y sus propiedades son determinadas a través de distintos parámetros como por ejemplo el Índice de Área Foliar (LAI por su sigla en inglés), la resistencia del canopy, la resistencia de las estomas de la vegetación, el albedo, la rugosidad, el porcentaje de raíz de vegetación en cada capa del suelo y el desarrollo que presenta la vegetación en superficie. El funcionamiento del modelo permite caracterizar la variabilidad de vegetación existente en cada celda de la grilla, por lo tanto dentro de cada una puede existir más de un tipo o clase de vegetación además de suelo desnudo; luego para cada clase se determinan los parámetros correspondientes. Los valores de los parámetros se obtienen de la clasificación de coberturas desarrollada por la Universidad de Maryland (Hansen et al., 2000) con resolución de 1 km. Esta clasificación utiliza datos de satélite (AVHRR) para proveer información global a 1 km de resolución de 14 tipos de cobertura, que incluye 12 clases de vegetación más 1 de suelo desnudo más 1 de agua. (Xie et al., 2004; Saurral et al., 2008; Su y Lettenmaier, 2009). Los parámetros del suelo que se usaron corresponden a la base de datos de la Organización de Agricultura y Alimento (FAO por su sigla en inglés) con resolución espacial de 5-minutos (FAO, 1998) que equivale a $1/12^\circ$. Estos parámetros incluyen la textura de suelo y densidad aparente, la porosidad, el potencial del suelo saturado, la conductividad hidráulica saturada, y el exponente de la curva de conductividad hidráulica no saturada basada en Cosby et al. (1984) (Gao et al., 2010).

3.2.1. Parámetros.

Los parámetros del suelo no presentan variación espacial dentro de la celda, son fijos y a diferencia de los de vegetación que revisten heterogeneidad, estos tienen un comportamiento uniforme en cada celda, y la variabilidad con que se genera la infiltración y el escurrimiento en la misma la aporta la curva de capacidad de infiltración variable de acuerdo a las condiciones de precipitación y de saturación, ver figuras 3.1 y 3.2.

Parámetro	Nombre	Rango Físico	Fuente
Vegetación	albedo α	0,10-0,20	Hansen et al. (2000)
	resistencia arquitectural r_a ($s m^{-1}$)	25,0-60,0	
	resistencia estomatal mín. r_m ($s m^{-1}$)	120-250	
	Índice LAI	0,02-5,00	
	rugosidad r_0 (m)	0,006-1,476	
	desplazamiento d_0 (m)	0,402-8,04	
	porosidad θ_s ($m^3 m^{-3}$)	0,404-0,523	
	potencial suelo saturado $\Psi_s(m)$	0,036-0,759	
	conductividad hidráulica saturada $K_s(m d^{-1})$	84,15-1218,24	
Suelo	exponente de curva de conductividad hidráulica no saturada c	3,05-13,00	FAO (1998)
	densidad ρ ($kg m^{-3}$)	1380-1600	
	exponente de curva de capacidad de infiltración variable b_i	0,001-0,400	
Calibración	espesor de capas de suelo $d_1, d_2, d_3(m)$	0,05-2,00	Gao et al. (2010)
	velocidad máxima del flujo base $D_m(m d^{-1})$	0-30	
	máxima fracción del flujo base D_s	0-1	
	máxima fracción del contenido de humedad del suelo de capa inferior W_s	0-1	

Cuadro 3.1: Parámetros de Vegetación y de Suelo que utiliza el modelo VIC, rango físico y fuente de la información.

Por otro lado existen también otros parámetros del suelo, distintos a los que se obtienen de la FAO, que se ajustan en calibración. En tabla 3.1 se presenta el conjunto de los parámetros de vegetación y de suelo, con el rango físico de valores de cada uno y su fuente de obtención, conjuntamente con los parámetro de calibración. Muchos de los parámetros de este modelo se basan en observaciones satelitales y/o son producto de investigación, algunos de ellos son tan heterogéneos espacialmente que las mediciones *in situ* no pueden capturar la efectividad a niveles regionales; otros son más conceptuales (como los espesores de las capas de suelo) y no se corresponden con cantidades físicas reales. Para estos parámetros, o hay que hacer suposiciones acerca de sus valores o bien hay que calibrarlos para minimizar las diferencias entre resultados del modelo y valores observados. A continuación se sintetizan los parámetros que generalmente son objeto de calibración y se describe brevemente cuál es su aporte físico en el modelado:

1. ds_{max} - [> 0 a ~ 30 , dependiendo de la conductividad hidráulica] Corresponde al máximo

flujo base que puede generarse en la capa de suelo inferior [$mm\ d^{-1}$].

2. ds - [> 0 a 1] Es la fracción de ds_{max} donde comienza el flujo base no lineal (de rápido incremento). Un valor alto de ds indica que el flujo base será alto con un bajo contenido de humedad en la capa de suelo inferior.
3. ws - [> 0 a 1] Es la máxima fracción de humedad del suelo (de la capa inferior) en la que se produce flujo base no lineal. Es análogo a ds , un valor alto de ws elevará el contenido de agua requerido para un crecimiento rápido del flujo (no lineal), que tenderá a retrasar los picos caudal.
4. b_i - [> 0 a $\sim 0,4$] Este parámetro define la forma de la curva de capacidad de infiltración variable. Describe qué cantidad de capacidad de infiltración existe en la celda como función del grado de saturación de la misma. Un valor alto de b_i da menor infiltración y mayor escorrentía superficial.
5. d_i (espesor de cada capa de suelo) - [normalmente de $0,05$ a $2,0$ m] El espesor de las capas de suelo afecta a muchas variables del modelo. En general, considerando solo escorrentía, las capas de suelo de mayor espesor, disminuyen los rápidos aportes de escorrentía (menor caudal pico), generando un hidrograma más dominado por el caudal base y aumentando las pérdidas debidas a la evapotranspiración.

En la figura 3.2 en su parte superior se muestra la curva de capacidad de infiltración variable encargada del aporte de variabilidad en los procesos de superficie a través de la función de probabilidad espacial, particionando la precipitación en dos procesos, por un lado infiltración y el otro proceso es escurrimiento directo R (Liang et al., 1996a,1996b); siguiendo el modelo *Xinanjiang* propuesto en Zhao et al. (1992) y cuya fórmula (A.8) de estimación se detalla en el anexo A. Los parámetros ds , ds_{max} , ws , y el espesor de la capa de suelo inferior (d_3) son los responsables de la generación del flujo base B o *baseflow*; que dependiendo de la relación entre ds y ws tendrá un comportamiento totalmente lineal (cuando $ds/ws = 1$) o tendrá un tramo lineal y otro tramo donde la generación del flujo base es de rápido crecimiento y no-lineal, que ocurre cuando $ds/ws < 1$. Mientras que el espesor de la capa más profunda (d_3) junto con la porosidad del suelo permiten determinar el máximo contenido posible de humedad en dicha capa ($w3_{max}$). El valor ds_{max} representa el máximo flujo base generado, asimismo el producto entre ds y ds_{max} define la cantidad de flujo base que se genera linealmente, mientras que la cantidad de humedad del suelo a partir de la cuál comienza a generarse el flujo no-lineal lo aporta el producto entre ws y $w3_{max}$. Las fórmulas para la estimación del flujo de base lineal y no-lineal se basan el modelo Arno desarrollado por Franchini y Pacciani (1991) y se encuentran detalladas en el anexo A.

También, en la parte inferior de la figura 3.2, se observan dos representaciones del flujo base para dos condiciones distintas de la relación ds/ws ; una cercana a la linealidad (curva verde) donde la relación es $0,8$ y otra curva en azul donde la relación es $0,25$, y donde existe un

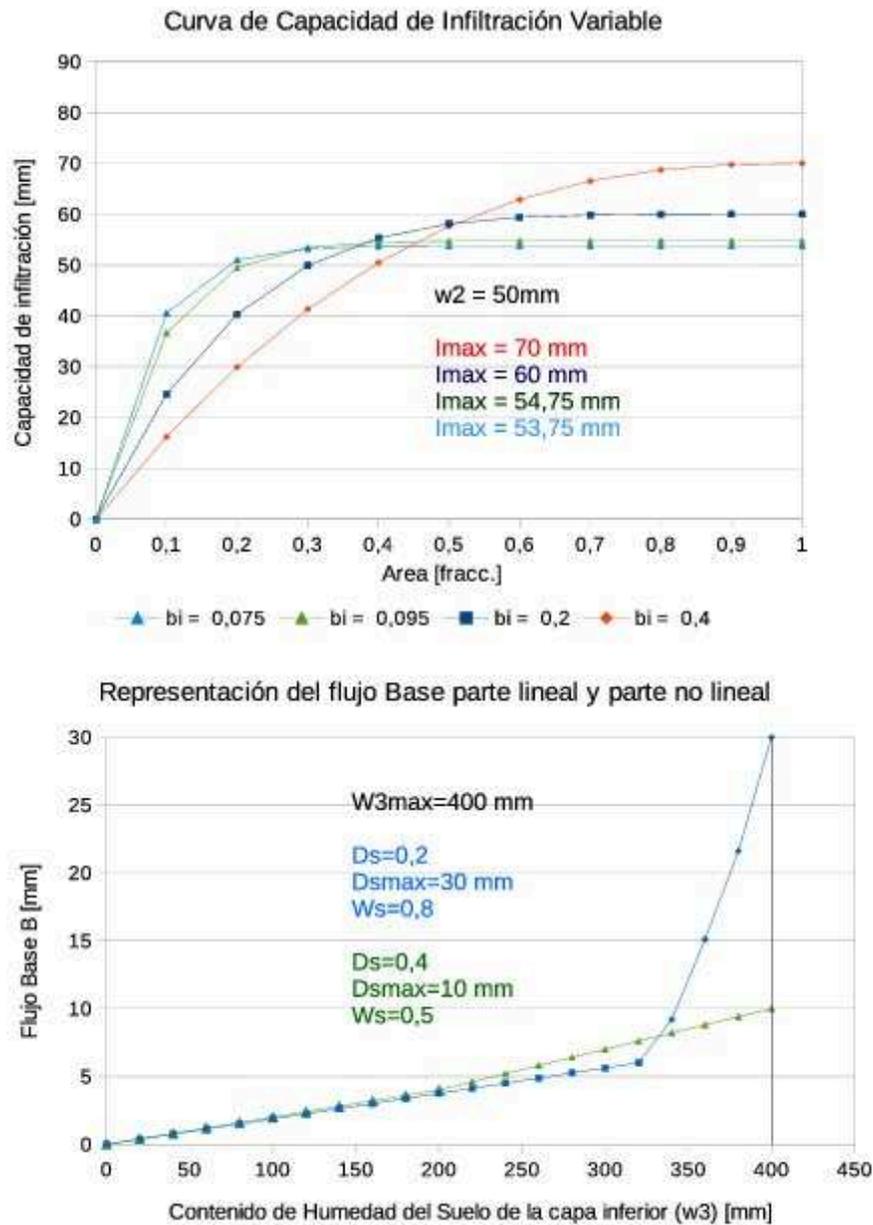


Figura 3.2: Curvas de Capacidad de Infiltración Variable y de generación del Flujo Base. Ejemplos de estimación para diferentes parámetros del suelo.

marcado aporte del flujo no-lineal en la generación de B. La curva verde muestra una relación prácticamente lineal en la determinación de B y donde el máximo flujo base se genera cuando se alcanza la máxima cantidad de humedad en la capa, entonces cuando $w3 = w3_{max}$ el flujo base generado es ds_{max} , es decir cuando $w3$ llega a los 400 [mm], B obtenido es 10 mm por paso de tiempo. Por otro lado la curva azul indica que cuando la capa contiene la máxima cantidad de humedad del suelo, el flujo base generado es 30 [mm] por paso de tiempo.

3.2.2. Análisis de Sensibilidad de Parámetros.

En una instancia previa a la calibración de los parámetros de suelo del modelo, se realiza un análisis de sensibilidad de cada uno de ellos a fin de detectar cómo influyen y con qué magnitud en la simulación del modelo. Para esto se ha establecido una situación de base con una condición inicial que será usada como control y que servirá luego para contrastar, a través de diferencias expresadas en porcentaje, con los resultados de cada simulación que ha sufrido la variación de un parámetro. Para aislar la sensibilidad intrínseca que produce cada parámetro, se los modifica de a uno por vez, luego se realiza una simulación diferente por cada parámetro modificado y se obtiene un estado de las variables simuladas por el modelo, que luego se evalúan con las mismas variables de la simulación de base, es decir de la condición inicial. En la tabla 3.2 se detallan los parámetros del modelo que se estudian en este análisis, conjuntamente con los valores de la condición inicial se encuentran los valores modificados de cada uno. La modificación de cada parámetro consiste en alterar un 20 % el valor que presenta la condición inicial y esa variación se hace en (+) y en (-). Por lo tanto como los parámetros del suelo son 7, se realizan un total de 14 simulaciones, 7 para los incrementos positivos (+20 %) y otras tantas para los negativos (-20 %). Los valores de los parámetros para la condición inicial corresponden a valores intermedios dentro del rango físico posible establecido en Gao et al. (2010); y por ejemplo, son además, del mismo orden de magnitud que los valores finales obtenido en Grimson et al. (2013).

Condición	bi	ds	ds_{max} (mm/d)	ws	d_1 (m)	d_2 (m)	d_3 (m)
Inicial (BASE)	0,1	0,5	10	0,5	0,1	1,0	2,0
(Base +20 %)	0,12	0,6	12	0,6	0,12	1,2	2,4
(Base -20 %)	0,08	0,4	8	0,4	0,08	0,8	1,6

Cuadro 3.2: Valores de parámetros para la condición inicial base del análisis de sensibilidad y valores modificados para las 2 condiciones consideradas.

Las simulaciones realizadas en esta etapa comprenden el período 1982-1990 utilizando datos de forzantes del CFSR (Saha et al., 2010) que ya ha sido analizado y estudiado en el capítulo 2, en este caso además de los datos de precipitación se agregaron los de temperaturas máximas y mínimas a 2m de superficie, y además datos de velocidad de viento meridional y zonal a 10m de altura. Los forzantes presentan un paso de tiempo 6-horario y una resolución original T382 de aproximadamente $0,3^\circ$ de lat/lon, estos datos fueron re-grillados utilizando una interpolación

de Bessel de tercer orden, recomendada para refinar la grilla de trabajo aumentando el nivel de detalle (<http://opengrads.org/doc/udxt/re/re.html>) y llevarlos a una resolución horizontal de $0,125^\circ$ de lat/lon. con este trabajo previo se generaron 18641 archivos de datos que corresponden a igual cantidad de celdas de $0,125^\circ \times 0,125^\circ$ de tamaño que abarcan el dominio completo de la cuenca del Plata. Del período completo de simulación 1982-1990, solo se consideraron para este análisis los datos correspondientes al rango de tiempo 1985-1990 y se descartaron los primeros 3 años por el '*spin up*' o tiempo de estabilización del modelo.

El control de la simulación se realiza a través de un archivo que permite, entre otras cosas, que ciertas características computacionales sean modificadas antes de iniciar la misma para indicarle al modelo las condiciones de simulación; por ejemplo el paso de tiempo, el período de simulación, cuáles son las variables que interesa simular, etc.. En este archivo se le indicó al modelo que genere salidas de campos superficiales del balance hidrológico a paso de tiempo diario para el período 1982-1990. Las variables simuladas por el modelo se muestran en la figura 3.3, como los valores medios diarios durante el período 1985-1990 para los campos de evapotranspiración (Evp), humedad del suelo en cada nivel (HdS_1 , HdS_2 y HdS_3), flujo base (B) y escurrimiento directo (R) que corresponden a la situación de la condición base. Estos campos constituyen las variables sobre las cuales se realizó el análisis de sensibilidad.

Las condiciones de la figura 3.3 muestran en general que las variaciones que presentan los campos simulados se encuentran relacionados con las variaciones que presenta el mapa de precipitaciones medias (ver figura 2.1a)), son dependientes de la precipitación aún para durante período promediado menor de solo 6 años. Donde los valores máximos de cada variable se encuentran sobre el norte, en el oeste en la zona de Los Andes y también en la región del centro de la cuenca del Plata cerca de su desembocadura; el campo de evapotranspiración muestra un comportamiento algo diferenciado con valores más elevados hacia el norte de la cuenca, pero también en la región de Chaco y Formosa.

También se destaca la vinculación que existe entre el contenido de HdS de la capa inferior (figura 3.3f)) y el flujo base (figura 3.3e)), otro tanto sucede entre el contenido de humedad de la capa intermedia y el escurrimiento directo, en las figuras 3.3d) y c) respectivamente. Los valores de HdS contenidos en la primer capa de suelo son considerablemente menores que los respectivos de las capas 2 y 3 debido principalmente a que la primera posee un espesor considerablemente menor que las capas que se encuentran por debajo. Una forma sintética para cuantificar las variaciones que muestran los campos simulados, y con ello el grado de sensibilidad que presenta cada parámetro sobre cada una de las variables, consiste en evaluar las diferencias expresadas en porcentaje respecto de la condición BASE, promediadas arealmente en las zonas de estudio 1 y 2 definidas con anterioridad. Las tablas 3.3 y 3.4 se encargan de mostrar dichas variaciones en porcentaje para ambas zonas, las variaciones que corresponden a los incrementos del 20% de los parámetros se muestran en negro, mientras que las variaciones que corresponden a los decrementos del 20% se aprecian en azul. La variable que se ve afectada en mayor porcentaje por la variación de los parámetros es el contenido de HdS, esto la convierte en la más sensible

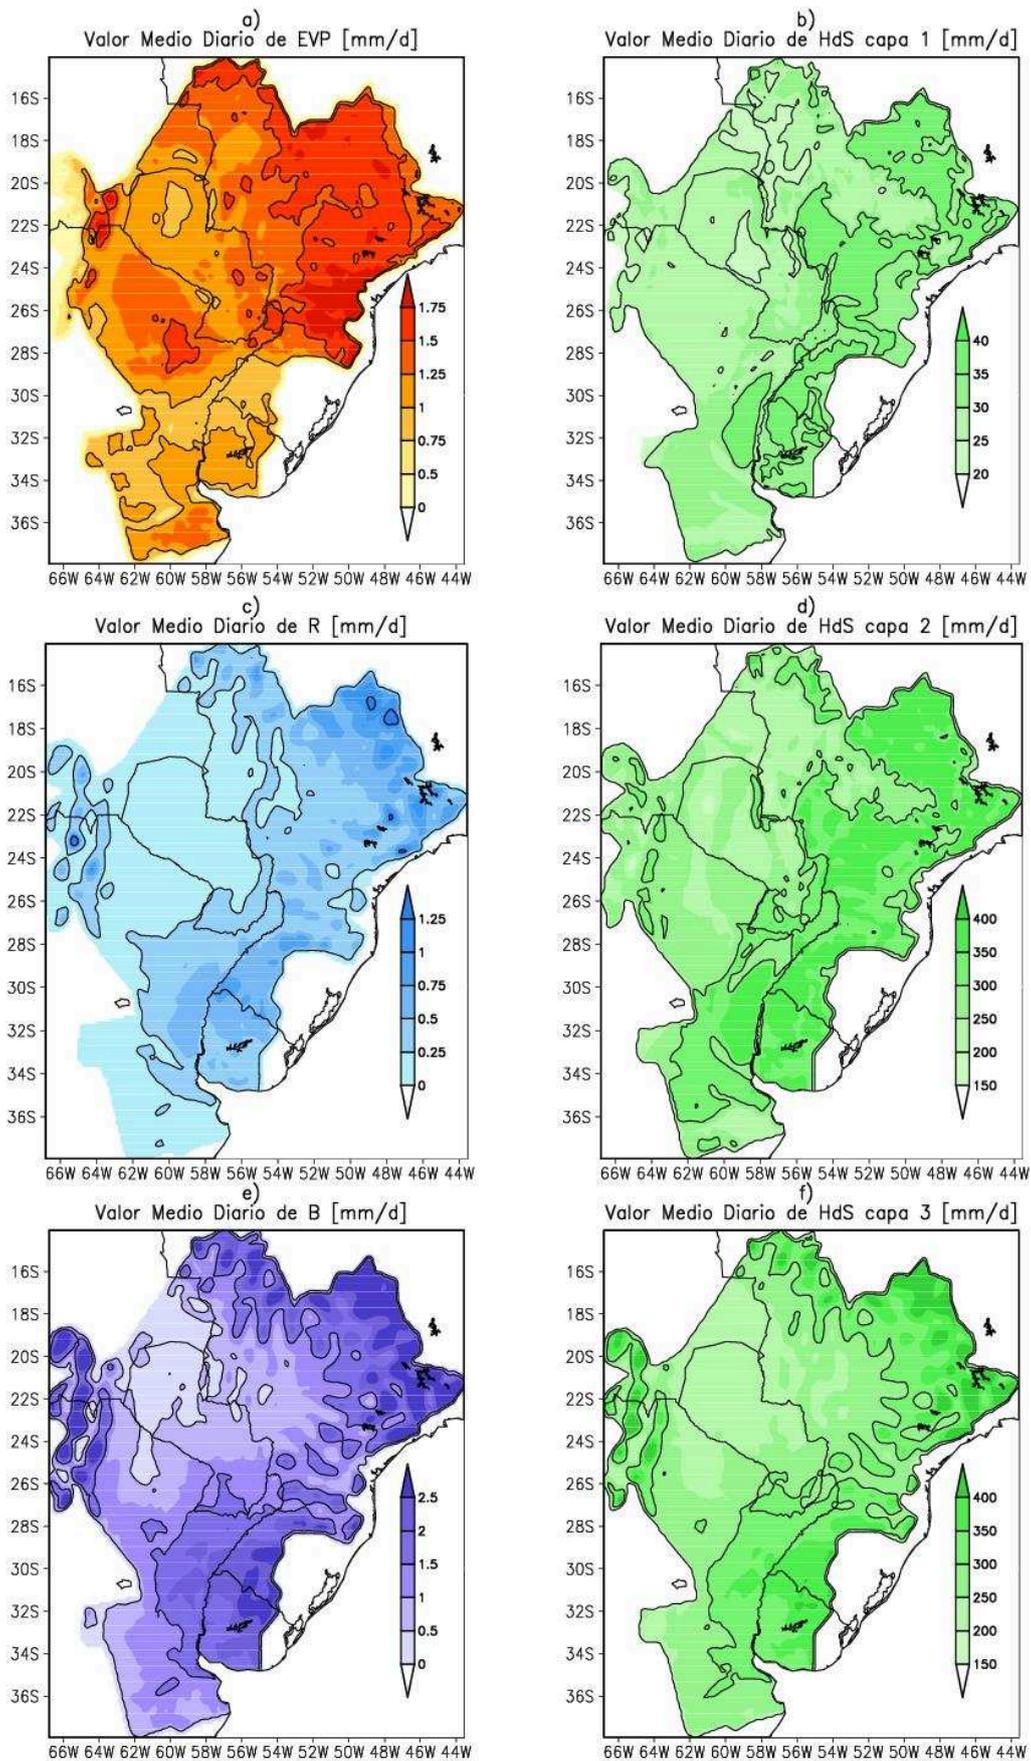


Figura 3.3: Valores medios diarios del período 1985-1990 correspondientes a la simulación con la condición BASE de los parámetros. a) Evapotranspiración (Evp), b) Humedad del Suelo en capa 1 (HdS_1), c) Esguimiento Directo (R), d) Humedad del Suelo en capa 2 (HdS_2), e) Flujo Base (B), f) Humedad del Suelo en capa 3 (HdS_3).

	bi + 20% bi - 20%	ds + 20% ds - 20%	dsmax+ 20% dsmax - 20%	ws + 20% ws - 20%	d1 + 20% d1 - 20%	d2 + 20% d2 - 20%	d3 + 20% d3 - 20%
HdS1	-0,1 0,1	-0,02 0,03	-0,02 0,05	0,03 -0,03	20,2 -20,0	0,2 -0,2	0,01 -0,01
HdS2	-0,2 0,2	-0,1 0,1	-0,1 0,2	0,1 -0,1	0,05 0,5	20,7 -19,9	0,01 -0,01
HdS3	-1,3 1,4	-5,7 8,0	-6,0 8,8	6,7 -6,7	0,02 0,3	-0,4 0,6	20,2 -20,3
R	14,6 -15,8	-0,1 0,1	-0,2 0,4	0,1 -0,1	-0,3 0,7	-2,4 4,0	-0,1 0,1
B	-3,3 3,6	0,4 -0,6	0,4 -0,7	-0,5 0,4	-0,03 1,5	-1,8 3,3	0,9 -1,3
Evp	-0,2 0,2	-0,1 0,2	-0,1 0,2	0,1 -0,1	-0,1 -1,0	2,2 -3,9	0,03 -0,03

Cuadro 3.3: Parámetros de suelo modificados en +20% (negro) y en -20% (azul) respecto de la condición BASE. Variación percibida en cada variable del modelo expresadas en porcentaje, respecto de la situación BASE. Valores promedios referentes a la Zona 1. El resaltado indica el parámetro que registra la mayor variación de una variable en particular

	bi + 20% bi - 20%	ds + 20% ds - 20%	dsmax+ 20% dsmax - 20%	ws + 20% ws - 20%	d1 + 20% d1 - 20%	d2 + 20% d2 - 20%	d3 + 20% d3 - 20%
HdS1	-0,1 0,1	-0,01 0,01	-0,01 0,01	0,01 -0,01	20,6 -20,4	0,1 -0,2	-0,01 0,001
HdS2	-0,2 0,2	-0,02 0,04	-0,02 0,04	0,03 -0,02	-0,04 0,2	19,7 -19,9	-0,02 0,02
HdS3	-0,8 0,8	-4,6 6,7	-4,7 6,9	5,4 -5,4	-0,04 0,2	-1,1 1,3	19,2 -19,9
R	15,3 -16,4	-0,03 0,1	-0,04 0,1	0,05 -0,04	-0,3 0,5	-2,6 4,1	-0,04 0,04
B	-2,6 2,8	0,8 -1,1	0,8 -1,1	-0,9 0,9	-0,1 0,8	-4,3 4,9	-2,4 0,8
Evp	-0,3 0,3	-0,1 0,1	-0,07 0,1	0,1 -0,1	-0,1 -0,8	2,2 -4,2	-0,1 0,06

Cuadro 3.4: Ídem Tabla 3.3 pero con valores referentes a la Zona 2.

de todas las analizadas, mientras que la evapotranspiración es la menos sensible y que menos variaciones en porcentaje registra, tanto para las variaciones en +20 % como en -20 %; esta característica se sostiene en las dos zonas.

Los parámetros que indican los espesores de las distintas capas de suelo son los más sensibles y son los que mayor variación aportan al contenido de humedad de la capa correspondiente, de forma que el parámetro d_1 es el más sensible cuando se evalúa el contenido de humedad de la primera capa. Cuando se incrementa d_1 , HdS_1 es la variable que mayor incremento registra con un porcentaje de 20,2 %, mientras que cuando disminuye el espesor de la primera capa en 20 % el contenido de humedad de la misma se reduce un 20,0 % en zona 1. Los porcentajes de variaciones de la humedad del suelo en capa 2 y 3 en relación a la modificación de los espesores d_2 y d_3 respectivamente, presentan alteraciones similares a las variaciones de humedad del suelo en la primera capa, cercanos al 20 %. Esta situación refleja una relación lineal entre el espesor de la capa de suelo y su contenido de humedad. Las variaciones de la humedad del suelo en cada una de las capas de zona 2 registran porcentajes similares a los reflejados en zona 1, reafirmando la relación lineal entre este parámetro y el contenido de humedad.

El espesor de la capa intermedia (d_2) también es el parámetro más sensible para la evapotranspiración, evidenciando que cuando se incrementa el espesor de la capa intermedia aumenta también la cantidad de evapotranspiración aunque en un porcentaje bastante menor, solo de 2,2 % en ambas zonas 1 y 2, probablemente debido a que en esta capa intermedia existe una mayor cantidad de raíces de vegetación que puedan extraer el contenido de humedad de la misma y evapotranspirarla, aunque los porcentajes indican que esta relación no es lineal. De igual manera cuando el espesor d_2 disminuye 20 %, el contenido de humedad en la capa 2 disminuye y la evapotranspiración registra un descenso de 3,9 % en zona 1 y de 4,2 % en zona 2.

El parámetro de forma de la curva de capacidad de infiltración variable (b_i) es el que produce mayor variación en R en la zona 1 cercano a una relación lineal, cuando se incrementa este parámetro el escurrimiento también se incrementa 14,6 % y cuando b_i disminuye 20 %, R disminuye casi 16 %. También resulta ser sensible a la generación del flujo base B pero en un carácter opuesto, ya que al incrementarse b_i , se registró una disminución de B de 3,3 % y cuando b_i disminuyó, el flujo base se incrementó 3,6 %. Este comportamiento opuesto reviste cierta lógica física, porque como ya hemos visto en la figura 3.2 cuando el valor de b_i disminuía favorecía la infiltración por sobre la generación de R y viceversa. De esta forma, al aumentar la infiltración favorece el aumento del contenido de humedad en cada capa de suelo, como también se aprecia en los valores correspondientes de las tablas 3.3 y 3.4 aunque en porcentajes muy bajos, incrementando a su vez el valor de B . En zona 2 los valores que registra R ante variaciones de b_i son similares a los de zona 1. Contrariamente a lo que sucede en zona 1, la mayor variación del flujo base en zona 2 se registra cuando se modifica el espesor d_2 , esta variación es de carácter opuesta y disminuye 4,3 % cuando se incrementa d_2 y aumenta casi hasta 5 % cuando d_2 disminuye. Los parámetros ds , ds_{max} y ws influyen en particular en el contenido de humedad de la capa de suelo inferior en ambas zonas, pero en porcentajes mucho menores que d_3 .

3.2.3. Análisis de Sensibilidad de Variables.

A continuación, se propone, modificar los valores de los datos forzantes de precipitación y de temperatura para crear una condición de sequía hipotética, y posteriormente evaluar los datos obtenidos bajo esta condición con los datos obtenidos utilizando los forzantes sin modificar; en ambos casos los parámetros de suelo serán los de la condición BASE que figuran en tabla 3.2. De esta manera se identifican cuáles son las variables que resultan más sensibles a una condición de sequía impuesta. En particular, la situación de sequía generada consiste en disminuir la precipitación en 10 % y en aumentar la temperatura del aire en el mismo porcentaje, de esta forma la reducción del agua disponible en superficie y el incremento de temperatura brindan condiciones propicias de un evento seco. Las simulaciones se realizaron para el período 1985-1990, de esta forma los campos medios diarios simulados de la condición inicial se corresponden con los de figura 3.3, mientras que en figura 3.4 se muestran las diferencias relativas entre la condición de sequía creada y la condición sin modificar.

Las dos variables que registran mayores diferencias entre ambas condiciones resultan ser el flujo base B y el escurrimiento directo R y ambas son negativas, como se ve en la figura 3.4e) y c) respectivamente. Es decir ante una condición de sequía propuesta estas variables son las que mayor impacto presentan mostrando disminuciones máximas localizadas, y el valor negativo indica la situación de déficit por la condición de sequía impuesta. El flujo base tiene disminuciones máximas entre 20-25 % en la región norte de la cuenca, entre Bolivia, Paraguay y Brasil, mientras que R también presenta variaciones negativas en esta región aunque con porcentajes algo menores entre 18-20 %. Las menores variaciones ocurren sobre Paraguay hacia el sur. La humedad del suelo contenida a diferentes profundidades también presenta disminuciones respecto a la condición BASE, las diferencias además aumentan con la profundidad, como se ve en las figuras 3.4b), d) y f) pero son menores que para B y R . La humedad de la primer capa de suelo presenta una diferencia negativa máxima que no llega al 1,5 % en la zona norte de la cuenca y oeste, y existe una región del centro de Paraguay donde la diferencia es 0 %. La capa intermedia muestra diferencias máximas en regiones puntuales similares a las de la capa superior con valores negativos entre 3-4 %; mientras que en la capa de suelo inferior la disminución máxima se registra en la región noreste de la cuenca con valores negativos entre 8-10 %.

La evapotranspiración es la única de las variables que presenta en algunas regiones de la cuenca una diferencia positiva sobre la condición sin modificar, como se muestra en la figura 3.4a). Esto implica que en las regiones donde hay valores positivos la condición de sequía propuesta no favorece la evapotranspiración ya que no existe cantidad de agua suficiente para evapotranspirar; los valores de incremento llegan hasta 5 % respecto de la condición BASE en regiones donde la climatología de Precipitación registra valores de moderados a elevados, ver figura 2.1a). Asimismo existen regiones como casi todo Paraguay donde se registran variación negativas de hasta 5 %. Las variables de mayor sensibilidad la constituyen principalmente los flujo base y el escurrimiento directo, seguido por la HdS de la capa inferior e intermedia. Estas variables

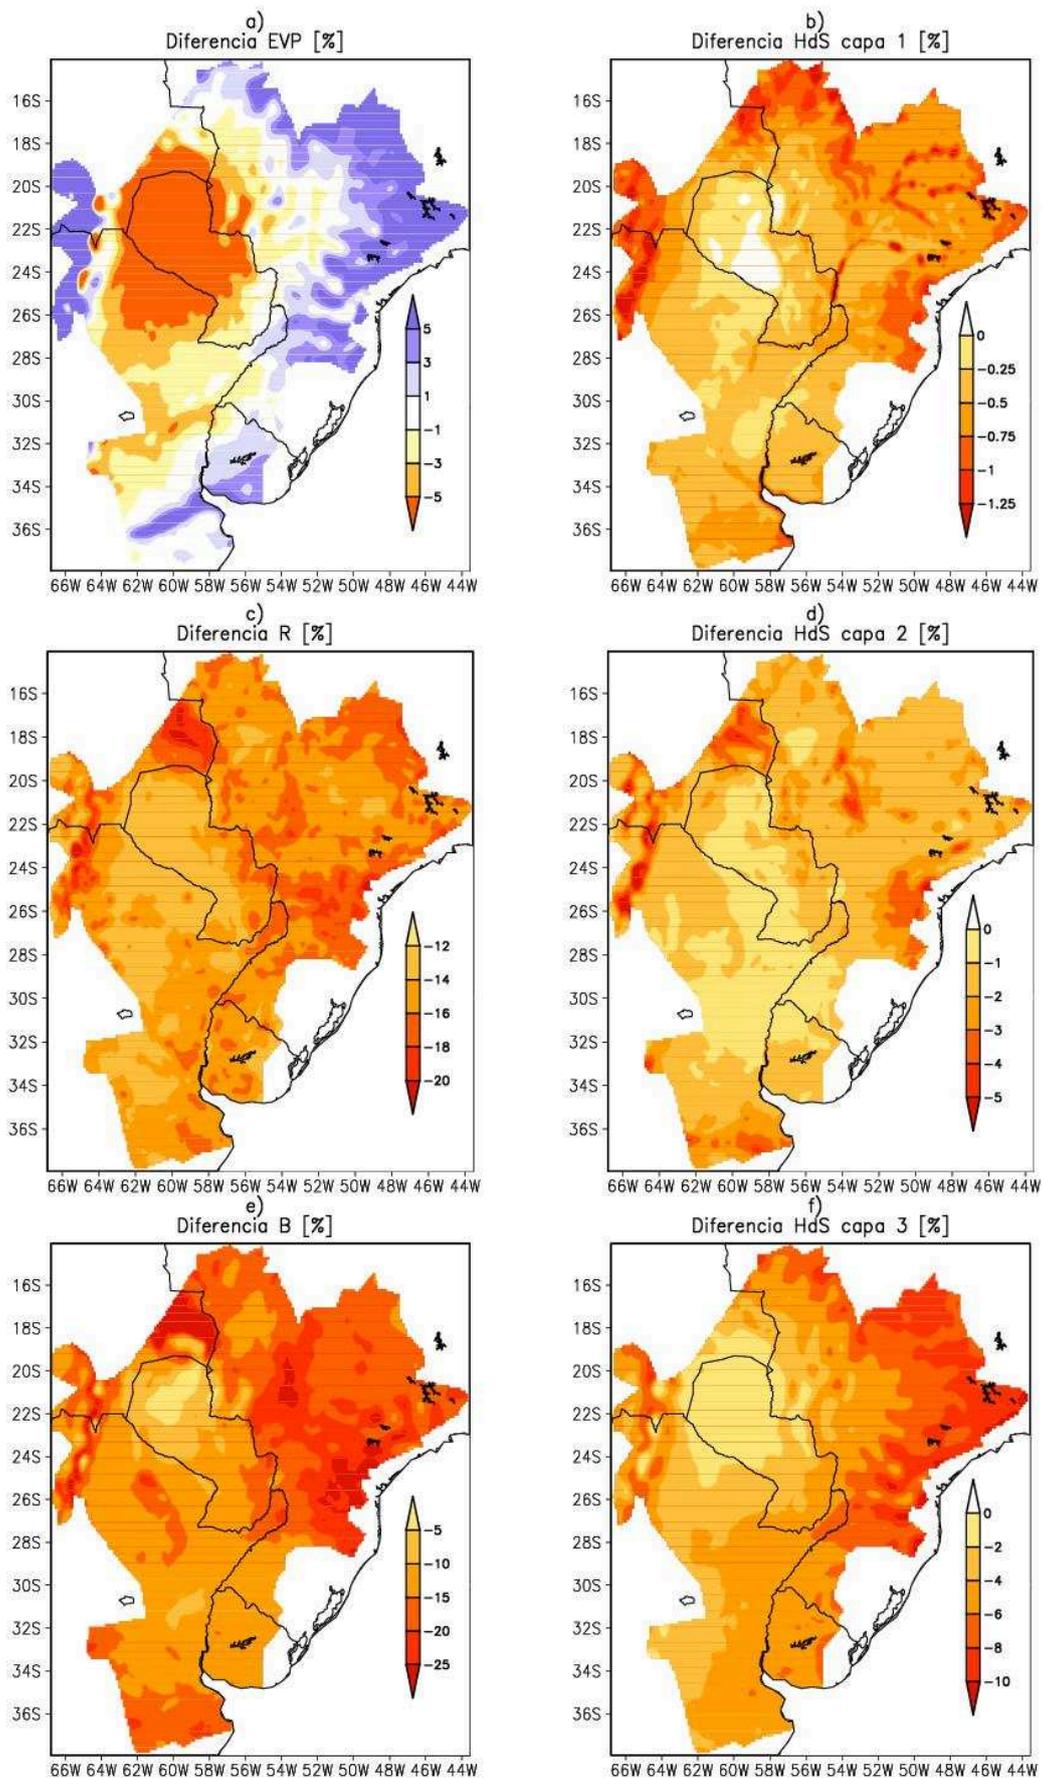


Figura 3.4: Diferencias relativas entre valores medios diarios simulados durante el período 1985-1990, de la condición de sequía propuesta y de la condición sin modificar. Para las variables a) Evapotranspiración, b) HdS en capa 1, c) R, d) ídem b en capa 2, e) B, f) ídem b en capa 3.

coinciden en mostrar en la región norte de la cuenca las mayores variaciones mientras que en la región central las variaciones son menores.

3.2.4. Calibración de Parámetros.

Los parámetros del suelo que figuran en la tabla 3.2 constituyen el grupo de parámetros que son objeto de calibración, en este trabajo los parámetros serán calibrados utilizando un conjunto de datos de humedad del suelo de un producto satelital. Las estimaciones satelitales de HdS consisten en un producto combinado generado a través de estimaciones derivadas de origen satelital y sensores de microondas, desarrollado por la Agencia Espacial Europea (ESA, por sus siglas en inglés), para generar una base de datos global. De acuerdo al Reporte de Caracterización de Errores, CECR (2012), las estimaciones de origen satelital son obtenidas de dos tipos de productos, unos que utilizan un sensor de microondas pasivos [SSMR, SSM/I, TMI, y AMSR-E] que cubren distintos períodos desde 1978 hasta 2008; y por otro lado sensores de microondas activos [SCAT y ASCAT] desde 1991 hasta 2008. Los primeros determinan la humedad del suelo expresado en contenido volumétrico de HdS [$m^3 m^{-3}$] a través de la constante dieléctrica. En cambio los de sensores activos expresan esta variable en grado de saturación del suelo [0 a 1]. Ambos productos satelitales estiman el contenido de la HdS en los centímetros superiores del mismo. Una serie de estudios han analizado los comportamientos de cada producto para representar la HdS comparándolos con mediciones *in situ* (Draper et al., 2009; Wagner et al., 2007) y determinaron que los valores obtenidos de los sensores pasivos tienen mejor performance en regiones donde la vegetación es pobre o escasa, mientras que donde la densidad de vegetación es moderada los datos del sensor de microondas activos presentaban un mejor ajuste. Por otro lado, en región intermedia de vegetación escasa a moderada, ambos algoritmos tienen comportamientos similares (Liu et al., 2011). Existen una serie de errores particulares en ambos tipos de sensores que afectan la estimación de la HdS en cada uno. Entre los activos, las fuentes de errores más comunes se deben a una topografía accidentada, cambios en la cobertura del suelo, cuerpos de agua en superficie, nieve y hielo, entre las más importantes; una manera de reducir estos errores es con el uso de máscaras (*flags*) que disminuyan el reflejo (*backscatter*) (CECR, 2012). Por otro lado los sensores pasivos sufren interferencias por las ondas de radio, debido a la vegetación excesiva, y también por hielo y nieve en superficie (CECR, 2012). En Dorigo et al. (2010) se ha determinado las regiones donde uno de los dos productos posee menores errores en la estimación (ver figura 3.5).

La base de datos desarrollada establece que debe existir un coeficiente de correlación igual o superior a $(r) = 0,65$ entre ambas fuentes de satélite, para garantizar que el error cuadrático medio (RMSE) entre las estimaciones y las observaciones *in situ* sea menor que 0,1 (Liu et al., 2011). Las regiones donde se reproducen estos valores de correlación corresponden a zonas donde se espera un fuerte acoplamiento entre precipitación y humedad del suelo (Koster et al., 2004). En la figura 3.5 se observa que para la región de la cuenca del Plata, en color azul en

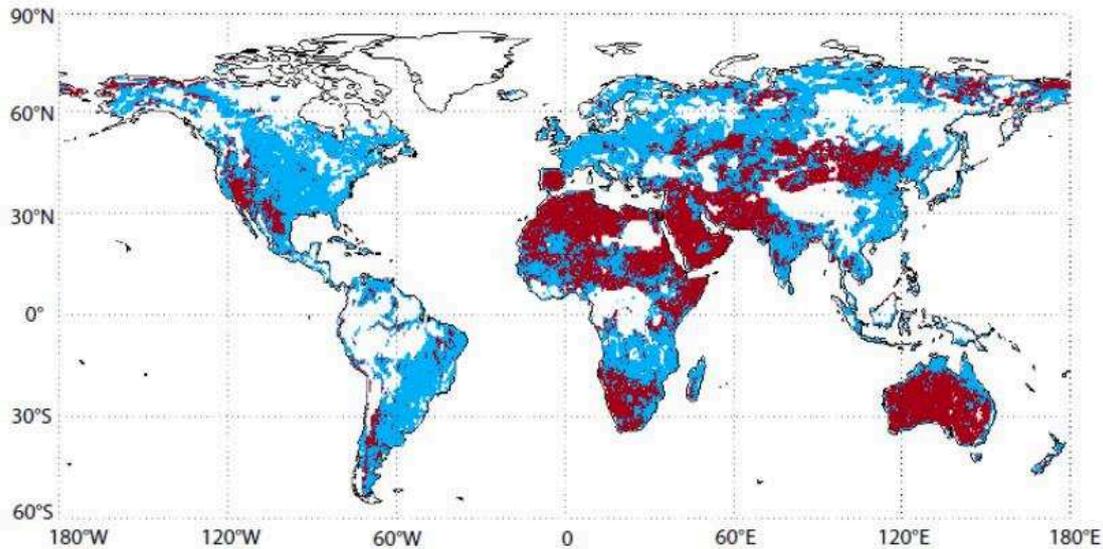


Figura 3.5: Muestra regiones donde estimaciones de los sensores [activos (azul) / pasivos (marrón)] presentan los menores errores en relación con mediciones in situ, las zonas en blanco registran poca cantidad de mediciones. Tomado de Dorigo et al. (2010).

su mayoría, existen errores menores de los sensores activos, no obstante puede suceder que las incertidumbres de cada producto individual se transfieran al producto combinado, e inclusive nuevas incertidumbres surjan en el proceso de combinación CECR (2012).

El producto final global ECV SM v02.0 (*Essential Climate Variable Soil Moisture, version 2,0*) (Liu et al., 2011; Liu et al., 2012), posee una resolución de $0,25^\circ \times 0,25^\circ$ y abarca el período desde noviembre 1978 hasta diciembre de 2013, originalmente hasta diciembre de 2008 pero se extendió hasta 2013. De esa base de estimaciones satelitales se usaron valores mensuales para comparar con los valores simulados de humedad del suelo durante el período 1985-1990, y realizar la calibración de los parámetros del suelo del modelo. Los valores simulados de humedad del suelo durante el período 1985-1990 fueron convertidos a valores mensuales previo a la calibración para equiparar el paso de tiempo del producto final global. Los datos simulados se encuentran en valores de $[mm\ d^{-1}]$, luego se divide el valor de humedad del suelo por el espesor en $[mm]$ de la capa de suelo que la contiene. De esta forma ambas fuentes de datos presentan la HdS expresada en $[m^3\ m^{-3}]$. Por último, antes de comenzar con la calibración, se realizó una redefinición de la resolución del producto combinado y se realizó un re-mapeo de estos datos para que coincidan con la resolución de los datos simulados. Asimismo se generó una máscara que contiene valores de las estimaciones satelitales que corresponden solamente a la región de la cuenca del Plata, y de esta forma permitir la comparación espacial de estimaciones y simulaciones punto a punto en todo el dominio.

Como una primera aproximación entre las estimaciones satelitales y las simulaciones, se evaluaron las diferencias entre ambas fuentes, y considerando la condición BASE de parámetros de la tabla 3.2 para la simulación. La evaluación se realizó a través del cálculo de las diferencias relativas expresadas en porcentajes entre valores medios de HdS simulados y valores de las es-

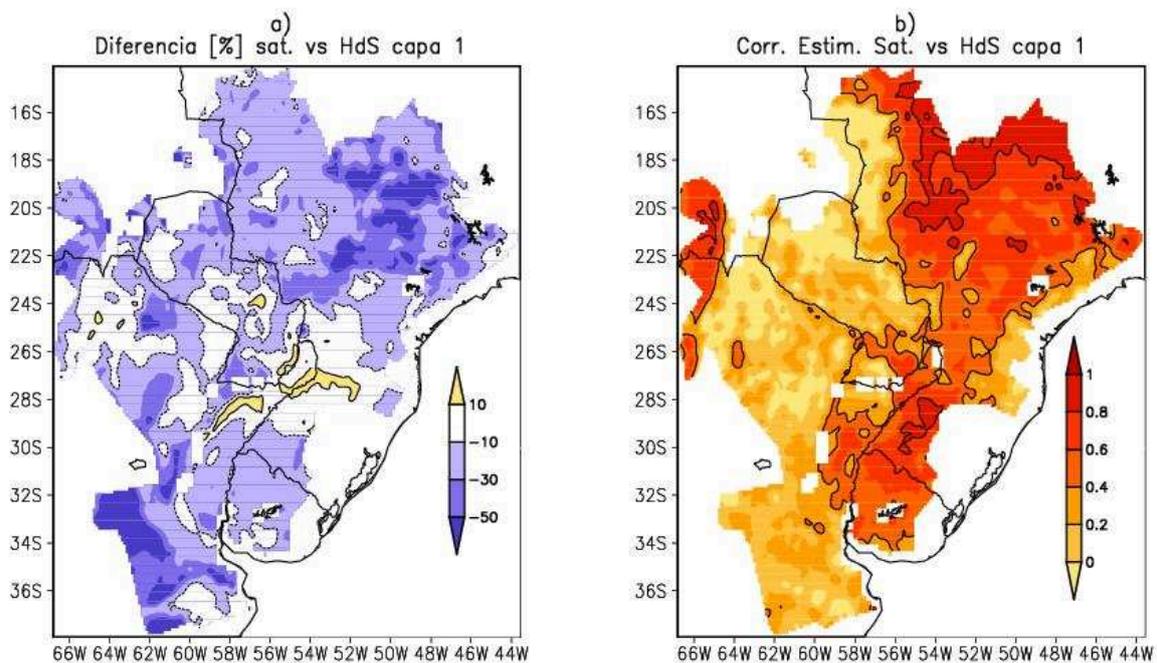


Figura 3.6: a) Diferencias relativas entre valores medios de humedad del suelo (condición inicial) correspondiente a la capa superior del suelo y las estimaciones satelitales, durante el período 1985-1990. b) Correlación temporal entre estimaciones y simulaciones a paso de tiempo mensual durante el mismo período y para la misma capa de suelo.

timaciones, divididos por las estimaciones para el período 1985-1990 como aparece en la figura 3.6a). El análisis fue realizado únicamente con los datos de la capa superior de los niveles de suelo del modelo, debido a que las señales de los productos de satélite solo consiguen estimar los valores de los centímetros superficiales del mismo (Liu et al., 2011); por lo tanto solo se consideraron simulaciones HdS_1 .

Existe una tendencia general a mostrar déficit por parte de la HdS simulada en casi toda la cuenca del Plata, como se destaca en figura 3.6a), evidenciando que esta constitución de parámetros usada subestima los valores de satélite, generando diferencias relativas negativas en gran parte del dominio. Llegando particularmente a -50% en la zona de la naciente del río Paraná, pero también en la parte sur de la cuenca que abarca el sur de Córdoba, centro de Buenos Aires y noreste de La Pampa. En sentido opuesto, en la región central de la cuenca se manifiestan en pequeñas regiones de Corrientes, Misiones y sur de Brasil, valores positivos de hasta 10% donde el modelo sobreestima a los valores de satélite. La figura 3.6b) muestra la valores de correlación temporal entre ambas fuentes durante el mismo período, destacando valores del coeficiente de correlación (r) $> 0,6$ en toda la porción este de la cuenca, así como también en el extremo oeste de la misma en la región limítrofe de Argentina y Bolivia. La parte central de la cuenca presenta correlaciones menores del orden de entre 0,4 y 0,2. En ciertas regiones del norte de la cuenca (r) llega a 0,8, posiblemente asociado con ciclos anuales de precipitaciones bien definidos en esta región evidenciando un mejor ajuste. De acuerdo con las diferencias encontradas, mayormente a que los valores simulados por el modelo subestiman a las estimaciones de satélite, además considerando que el parámetro del espesor de la capa superior

(d_1) es el más sensible para evaluar el contenido de HdS_1 ; se considera, por lo tanto, aumentar el valor de d_1 generando un incremento de la humedad en esta capa (HdS_1). De igual forma se incrementa el espesor de la capa de suelo intermedia (d_2) lo que también implica un leve aumento de la HdS_1 . Por otro lado, se reduce el parámetro de forma de la curva de capacidad de infiltración (b_i), esta disminución aumenta la cantidad de agua infiltrada incrementando entre otros el contenido de HdS_1 , de acuerdo con las variaciones presentadas en las tablas 3.3 y 3.4. Lo que se trata con estas modificaciones es que no solo se incremente el contenido de HdS en la capa superficial, sino que también pueda representarse la variabilidad de este campo en forma consistente.

	b_i	ds	ds_{max} (mm/d)	ws	d_1 (m)	d_2 (m)	d_3 (m)	BIAS(%)	SRMSE	NSE
Set 1	0,09	0,5	10	0,5	0,11	1,1	2,0	-20,3	0,53	0,49
Set 2	0,085	0,5	10	0,5	0,12	1,2	2,0	-9,2	0,52	0,53
Set 3	0,08	0,5	10	0,5	0,13	1,25	2,0	-5,4	0,49	0,54
Set 4	0,08	0,5	10	0,5	0,13	1,3	2,0	-4,8	0,48	0,54

Cuadro 3.5: Set de parámetros usados en la calibración de la humedad del suelo simulada, para el período 1985-1990. Medición del ajuste de cada set de parámetros en la cuenca del Plata, utilizando BIAS, el error cuadrático medio estandarizado (SRMSE), y el coeficiente de Nash-Sutcliffe (NSE), como funciones objetivos.

En tabla 3.5 se consideran condiciones establecidas para simulación, cuatro sets que detallan distintos parámetros del suelo. Cada set presenta modificaciones en los parámetros mencionados en el párrafo previo, mientras que los parámetros ds , ds_{max} y ws , se dejan invariantes respecto de la condición BASE, ya que son los parámetros menos sensibles de todos los evaluados. La calibración de los parámetros del suelo se realizó durante la ventana 1985-1990, para este período se determinaron valores mensuales tanto para registros simulados como para las estimaciones, y se analizaron los resultados mediante tres funciones objetivos (Moriassi et al., 2007), el BIAS expresado en porcentaje, SRMSE o error cuadrático medio estandarizado que corresponde al valor de RMSE (ya presentado en el capítulo 2), pero dividido por el desvío estándar de las estimaciones (SDy_i), y el NSE o coeficiente de Nash-Sutcliffe, cuyas fórmulas 3.1, 3.2, y 3.3 se presentan a continuación.

$$BIAS = 100 * \frac{\sum_{i=1}^n (\hat{y}_i - y_i)}{\sum_{i=1}^n (y_i)} \quad (3.1)$$

$$SRMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}}{SDy_i} \quad (3.2)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (3.3)$$

En cada una de estas fórmulas, y_i representa el valor estimado de satélite, y \hat{y}_i el valor simulado.

Los valores de cada coeficiente fueron evaluados en toda la cuenca del Plata, y para cada uno de los sets de parámetros, los valores medios de todo el dominio se muestran en las tres últimas columnas de la tabla 3.5. Asimismo se determinaron, también, los valores punto a punto en la cuenca durante el período de calibración, como se puede ver en las figuras 3.7 para los sets 1 y 2, mientras que para los sets 3 y 4 en la figura 3.8.

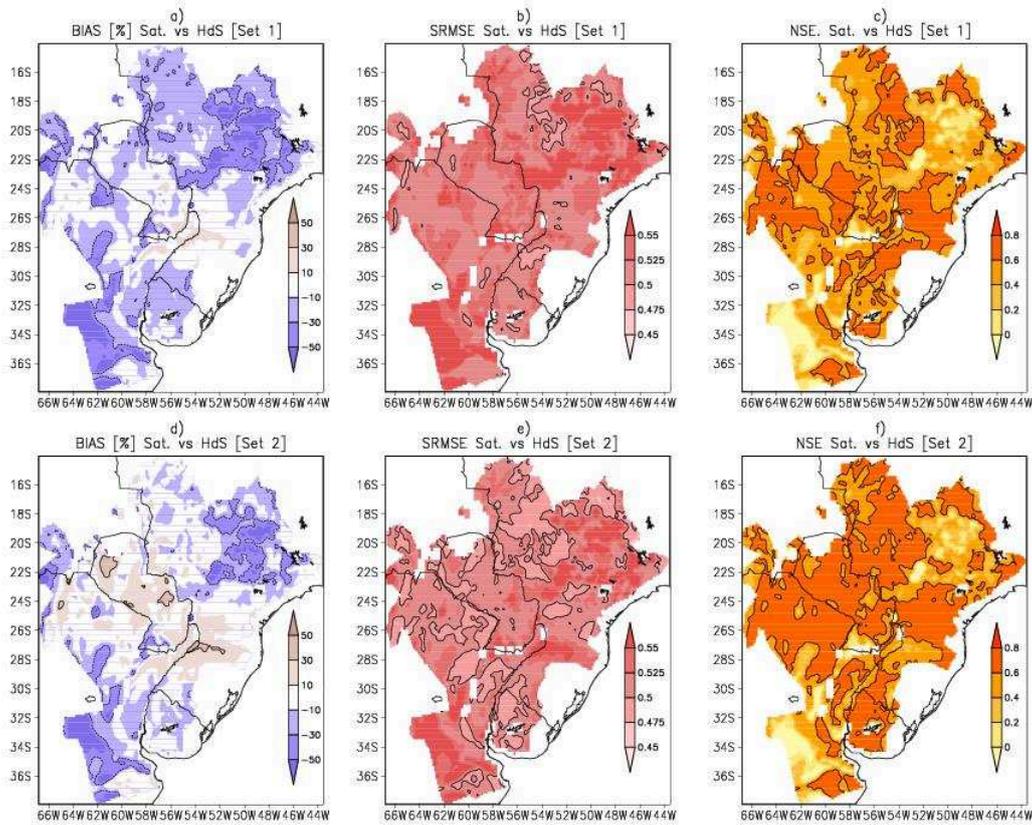


Figura 3.7: Análisis entre estimaciones satelitales y simulaciones de HdS_1 , mediante: a) BIAS (%), b) SRMSE, c) NSE para el set 1 de parámetros. d), e), f) ídem a), para el set 2 de la tabla 3.3.

Los porcentajes del BIAS muestran en la figura 3.7a) una distribución similar al patrón de diferencias relativas encontradas en la figura 3.6a) pero con diferencias menores. Es decir que el incremento de d_1 ha aumentado la HdS_1 y esto se refleja en una disminución del porcentaje subestimado por parte del modelo respecto a las estimaciones satelitales, además existe un aumento de las regiones donde los porcentajes se encuentran entre -10% y 10%, que reflejan valores del BIAS aceptables. Algo similar ocurre para el set 2 en el panel d) de la figura 3.7, el cual también muestra regiones donde el modelo comienza a sobreestimar los valores de satélite, este set presenta un incremento de d_1 y d_2 respecto al set 1 y una disminución del parámetro de curva (b_i). Tanto el panel b) como el e) de la figura 3.7 muestran que la cuenca prácticamente en su totalidad presenta valores de SRMSE menores a 0,6, estos valores del error cuadrático medio estandarizado se encuentran en el límite superior de lo aceptable de acuerdo a Moriasi et al. (2007) y por lo tanto sería deseable disminuirlo. Los valores de SRMSE más altos coinciden con las regiones donde el BIAS es más negativo, esto podría indicar que el SRMSE se reduciría en estas zonas si el valor negativo del BIAS aumenta haciéndose más positivo. Los valores del

coeficiente NSE son satisfactorios, con $NSE > 0,6$ en la parte central y norte de la cuenca, y cercanos a 0,4 en la parte sur y noreste de la misma, también en coincidencia con las regiones donde el BIAS es más negativo. La distribución espacial del BIAS en el panel d) mejora al set 1, y también muestra una reducción del SRMSE en las zonas donde el BIAS negativo aumentó.

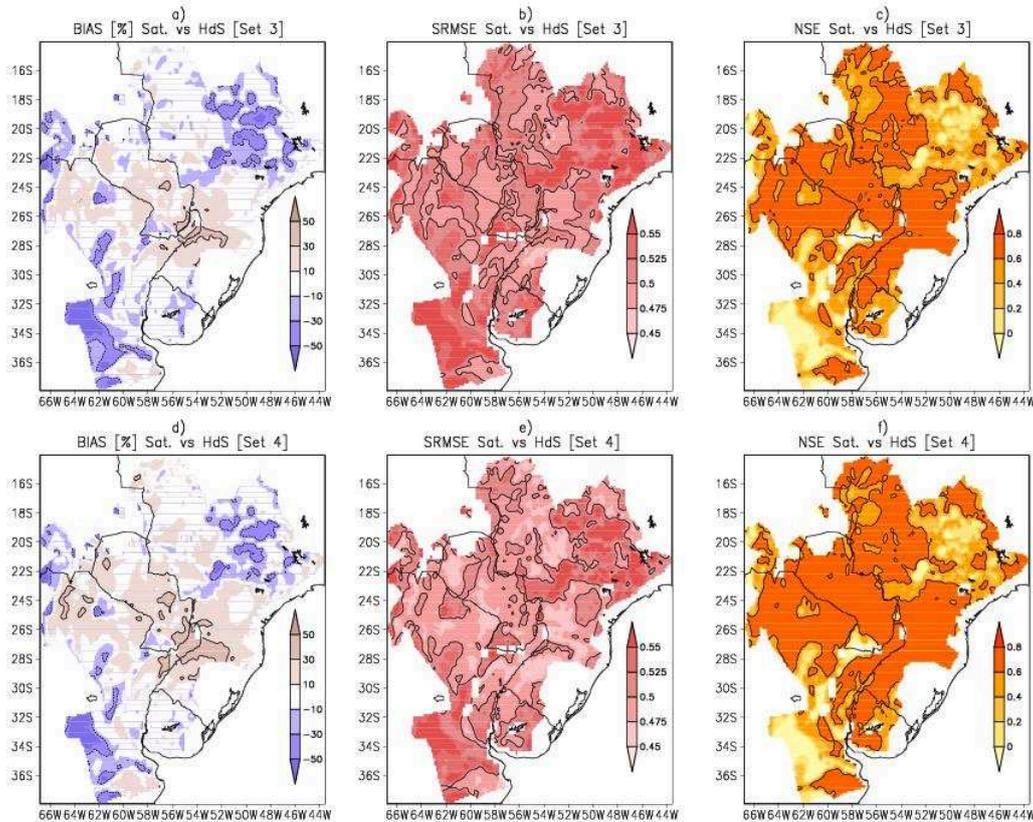


Figura 3.8: Análisis entre estimaciones satelitales y simulaciones de HdS_1 , mediante: a) BIAS (%), b) SRMSE, c) NSE para el set 3 de parámetros. d), e), f) ídem a), para el set 4 de la tabla 3.3.

El tercer set de parámetros en figura 3.8 muestra un aumento del BIAS en relación con los set 1 y 2 debido al incremento de los espesores d_1 y d_2 , y la disminución de b_i , no obstante siguen existiendo regiones donde el valor continúa siendo negativo con valores de -30%. Este no es un valor óptimo, pero se encuentra cerca de -25% que es aceptable según Moriasi et al. (2007). BIAS positivo del 30% en la región de Misiones, y algo menor en la región central de la cuenca, indican que en esa zona un incremento de d_1 aumentaría el BIAS y lo haría más positivo. En el panel d) de la figura 3.8 se aprecia un leve aumento del BIAS, que se debe al incremento del espesor d_2 , que representa la única diferencia entre los sets de parámetros tercero y cuarto. Entre estos dos últimos sets solo existe una mínima reducción del SRMSE como se observa en los paneles b) y e) de la figura 3.8 en regiones donde el BIAS del panel d) es levemente positivo. Por otro lado los paneles c) y f) referentes al coeficiente NSE no presentan diferencias sustanciales, esto indica que este coeficiente no es muy sensible a las variaciones entre los sets de parámetros 2-4, y siguen mostrando regiones donde el valor del coeficiente es de alrededor de 0,4, en particular en el sur de la cuenca.

Los valores medios de los coeficientes evaluados en toda la cuenca ponen de manifiesto las

mejoras del ajuste en cada uno de los set propuestos para la calibración. En particular los grupos de parámetros 3 y 4 son lo que mejores valores muestran en el análisis de la cuenca completa, y es el último set de parámetros el que tiene el menor valor del BIAS para la totalidad de la misma, por lo tanto se definen a los parámetros del grupo 4 como los parámetros de suelo del modelo calibrado. El ajuste mostrado espacialmente a través de las evaluaciones mediante las funciones objetivos es aceptable y promisorio. Posteriormente se analiza el comportamiento temporal y la vinculación que existe entre los valores simulados y las estimaciones de satélite, y determinar si los valores simulados de HdS acompañan la dinámica de variación de la HdS de las estimaciones de satélite en la cuenca. Para analizar esto se determinaron series temporales medias de la cuenca del Plata, de estimaciones satelitales y de las simulaciones de HdS_1 ; considerando en una primera instancia la condición BASE de parámetros y luego el set 4 de calibración del modelo para determinar como mejora el ajuste con la calibración, este análisis se puede ver en la figura 3.9.

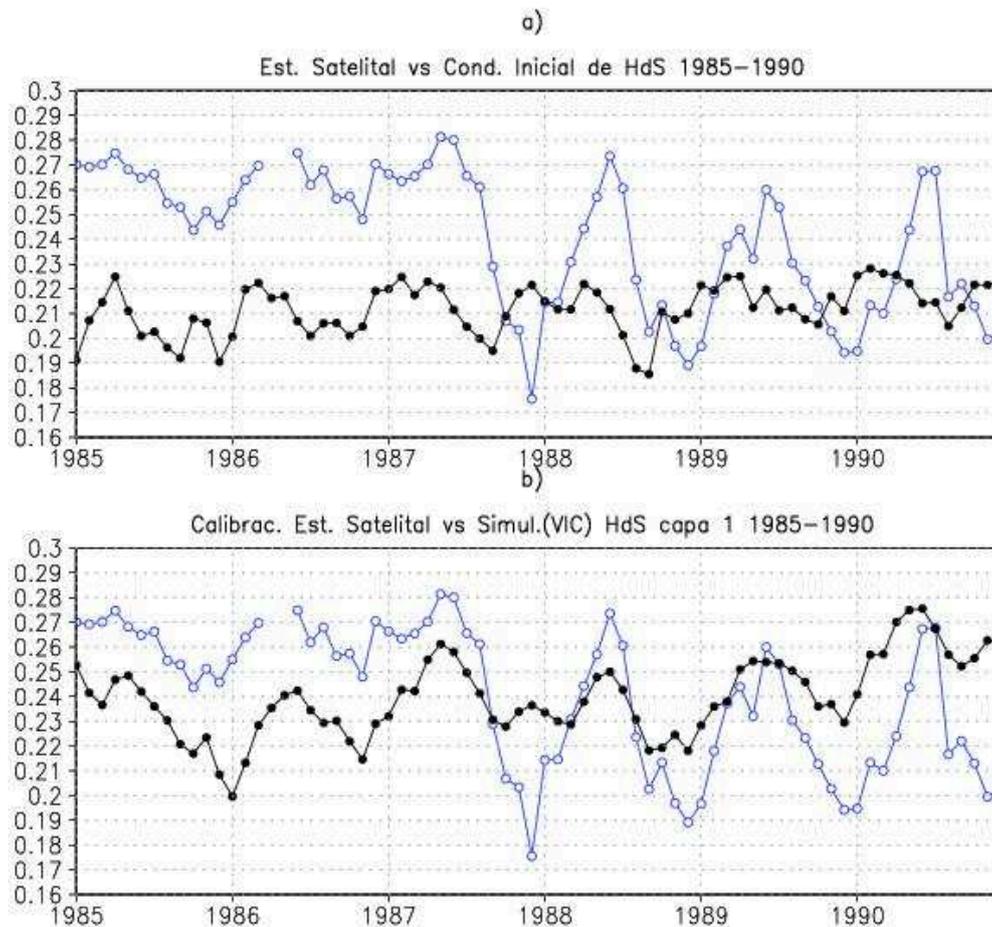


Figura 3.9: Series temporales de datos mensuales para la cuenca del Plata durante 1985-1990, de humedad del suelo estimada (azul) versus simulada (negro). a) Simulación con la condición BASE de parámetros. b) Simulación con set de parámetros del modelo calibrado.

En la figura 3.9a) se aprecia que la serie de HdS_1 para la condición BASE, si bien representa la dinámica de humedad del suelo estimada en la cuenca, por un lado lo hace por defecto en prácticamente todo el período y solo por exceso los meses de verano de los años 1988, 89, y 90. Por otro lado presenta muy poca amplitud en relación con las variaciones de las estimaciones

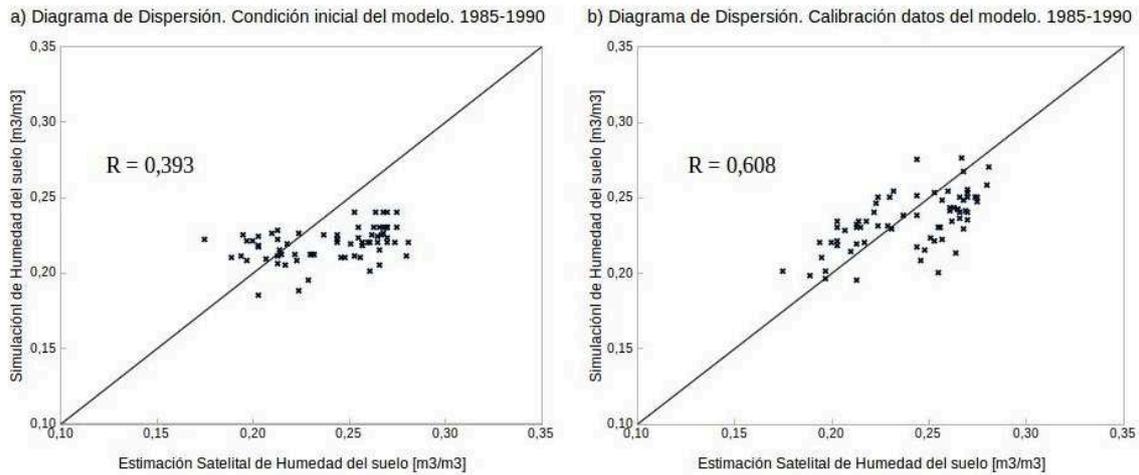


Figura 3.10: Diagramas de dispersión entre estimaciones satelitales y simulaciones de HdS, para la cuenca del Plata durante 1985-1990. a) Simulación con condición BASE de parámetros. b) Simulación con set de parámetros del modelo calibrado.

de satélite, lo que produce un ajuste muy pobre. Los diagramas de dispersión de ambas series se muestran en la figura 3.10a) y se puede observar a los valores simulados por debajo de la diagonal mayormente, con un valor de $(r) = 0,393$ que es muy bajo. Los valores de HdS estimados presentan una suave variabilidad entre 1985-1987 con 2 datos faltantes hacia fin de 1986. Entre 1988-1990 la variabilidad es más marcada con valores máximos a mitad de año y mínimos en verano. Los datos de HdS_1 del panel b) de la figura 3.9 corresponden al modelo calibrado, y muestran una mejor representación del comportamiento de la HdS estimada, si bien continua siendo por defecto durante el período 1985-87, esa diferencia se presenta más reducida y se observa una dinámica similar a las estimaciones. El incremento de los espesores d_1 y d_2 ha mejorado la respuesta del modelo a las estimaciones, esto produjo un incremento en la amplitud de la serie simulada mejorando la variabilidad y la representación. Este comportamiento también se refleja en el panel b) de la figura 3.10 donde ambos datos se ajustan más a la diagonal y donde el coeficiente de correlación $(r) = 0,608$, mejora sustancialmente.

3.2.5. Validación.

Durante esta parte del trabajo se evalúa el set de parámetros con que se calibró el modelo pero durante un período de tiempo diferente, de esta manera se busca determinar si los valores de los ajustes obtenidos durante el proceso de calibración se mantienen cuando se evalúa un período distinto. En este sentido se simuló valores de HdS_1 y se compararon con estimaciones satelitales mensuales de HdS de la misma base de usada en calibración, pero durante el período 1991-2010 en la cuenca completa. En la tabla 3.6 se muestra el set de parámetros con los que se realizó la simulación y los valores de los coeficientes que se usaron para evaluar la simulación en esta etapa.

Los coeficientes que evalúan el ajuste, BIAS, SRMSE y NSE muestran durante el período

	bi	ds	ds_{max} (mm/d)	ws	d_1 (m)	d_2 (m)	d_3 (m)	BIAS(%)	SRMSE	NSE
Set 4	0,08	0,5	10	0,5	0,13	1,3	2,0	5,5	0,415	0,625

Cuadro 3.6: Validación del set de parámetros de mejor ajuste en la cuenca del Plata para el período 1991-2010. Utilizando BIAS, el error cuadrático medio estandarizado (SRMSE), y el coeficiente de Nash-Sutcliffe (NSE), como funciones objetivos.

de simulación 1991-2010 una distribución espacial semejante a lo obtenido en el período de calibración. En la figura 3.11a) el BIAS muestra regiones menores con valores negativos respecto a figura 3.8d) y los valores positivos abarcan una región mayor; esto se manifiesta en el valor 5,5% obtenido para toda la cuenca durante esta nueva etapa. Este incremento del BIAS ha mejorado la distribución del error bajando los valores de SRMSE en gran parte de la cuenca, como se destaca en el panel b), además se observa, en este mismo panel, que las regiones en rojo más intenso equivalentes a un valor del error de 0,5 han reducido su tamaño en relación al mismo diagrama de la etapa de calibración; mejorando el valor medio del SRMSE para toda la cuenca siendo igual a 0,415. El diagrama el coeficiente NSE también registra una mejora en relación a los valores de calibración con un valor de 0,625 en la cuenca. Además la distribución espacial de la figura 3.11c) muestra que existe una mejora en parte de zona norte y también de zona sur respecto a la etapa de calibración extendiendo el área con valores aceptables de este coeficiente. En la región sur de la cuenca existe, además, un aumento del valor NSE entre 0,4 y 0,6 en la parte de la misma que corresponde a la zona 2, que en la etapa previa presentaba valores más cercanos a 0,2.

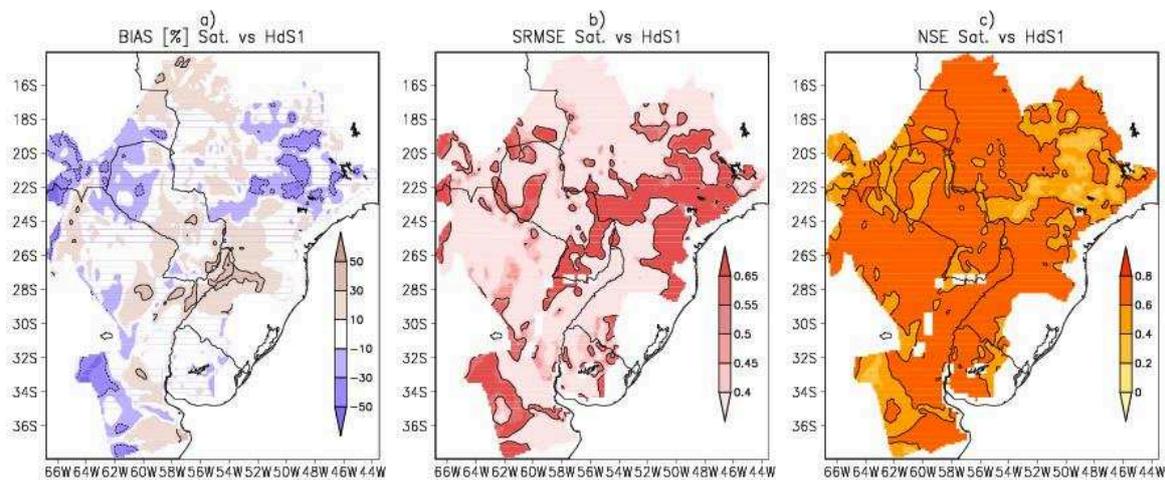


Figura 3.11: Análisis entre las estimaciones satelitales y las simulaciones de HdS_1 . Durante la etapa de Validación 1991-2010: a) BIAS (%), b) SRMSE, c) NSE.

El comportamiento temporal analizado en la serie del panel izquierdo de figura 3.12 permite identificar la habilidad de la HdS simulada para representar la dinámica de comportamiento que presentan las estimaciones de satélite de HdS , mejorando también el ajuste respecto de la etapa de calibración. Esto representa una mejora destacable respecto a la etapa previa, y se observa tanto en el diagrama de dispersión del panel derecho de figura 3.12, como en el

coeficiente de correlación del ajuste (r) = 0,754.

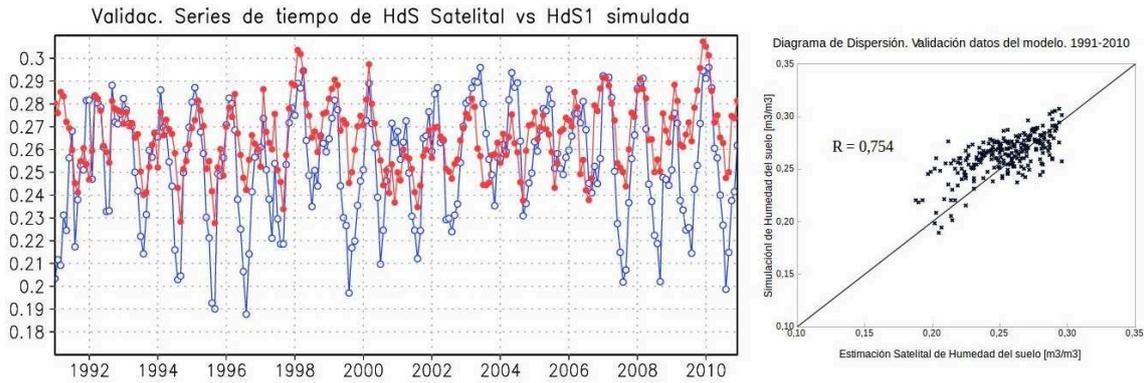


Figura 3.12: IZQ: Series temporales de datos mensuales de HdS estimada (azul) versus simulada (rojo). DER: Diagrama de dispersión entre estimaciones satelitales y simulaciones de HdS. Para la cuenca del Plata durante el período de validación 1991-2010.

Esta habilidad demostrada por el modelo para representar la dinámica de las estimaciones satelitales de humedad del suelo, lo ubica en una posición promisoriosa para desarrollar los estudios restante de esta tesis. Hay que destacar que solo el contenido de humedad de los centímetros superiores del suelo es lo que se obtiene de las estimaciones satelitales, ya que los sensores solo permiten detectar la humedad en esta parte del mismo; y es el contenido de humedad de esta parte del suelo la que ha sido evaluada durante las etapas de calibración y validación. Más aún, el contenido de humedad de esta primera capa de suelo del modelo, se encuentra afectado por mecanismos de aporte de humedad desde la capa inferior y esto afecta al ajuste entre las simulaciones de HdS_1 y las estimaciones satelitales. Principalmente debido a que se utiliza una discretización conceptual que particiona al suelo en profundidad, dividiéndolo en 3 capas para representar la complejidad de los procesos de superficie. Los efectos que produce esta discretización se manifiestan en que la humedad contenida en la capa intermedia produce un aporte de humedad a la capa superior a través del proceso de difusión, cuando el contenido de humedad de la capa intermedia es mayor que el de la capa superior; generando que la serie temporal de HdS_1 tenga una amplitud más reducida, respecto de la estimada por satélite. Esto produce que la HdS_1 no descienda lo suficiente cuando existe ausencia de precipitación disminuyendo la variabilidad.

3.3. Conclusión.

Se ha implementado el modelo de capacidad de infiltración variable en la cuenca del Plata y se lo utilizó para simular campos de variables de superficie forzando al mismo con datos del reanálisis de CFS, utilizando datos de parámetros del suelo y de vegetación, de la FAO y de la Universidad de Maryland respectivamente. Durante las etapas de calibración y validación los datos simulados de HdS fueron evaluados con datos derivados de estimaciones de satélite, mediante un producto combinado basado en estimaciones de escaterómetros y radiómetros. El

ajuste cuando se usa la condición BASE, indica una alta correlación en regiones donde el ciclo anual de lluvias es bien marcado con un valor del coeficiente de correlación $(r) = 0,8$; para el resto de la cuenca los ajustes se reducen hacia el oeste y sur. Se evaluaron las diferencias relativas durante el período 1985-1990 en toda la cuenca, y los resultados indican que la humedad del suelo simulada subestima a las estimaciones satelitales.

El análisis de sensibilidad de parámetros estableció que el espesor de la capa de suelo es el más sensibles de todos los parámetros sujetos a calibración, y la variable que mayor sensibilidad evidenciaba era la humedad del suelo en la capa correspondiente. La relación de sensibilidad existente entre ambos, parámetro y variable, es lineal. Para reducir las diferencias relativas y mejorar el ajuste se propusieron 4 conjuntos de parámetros modificando los más sensibles. De esta forma se consiguió principalmente aumentar el contenido de HdS de la primera capa, y agregar variabilidad a las series temporales. En calibración se determinó una serie de valores de parámetros que reducen las diferencias entre las estimaciones y las simulaciones. Los valores de los parámetros del modelo calibrado son $b_i = 0,08$, $ds = 0,5$, $ds_{max} = 10$ [mm d^{-1}], $ws = 0,5$, $d_1 = 0,13$ [m], $d_2 = 1,3$ [m] y $d_3 = 2,0$ [m]. Las funciones objetivos usadas mostraron valores medios de BIAS de -4,8 %, de SRMSE de 0,48 y de NSE de 0,54 que resultan satisfactorios. Los valores en la etapa de validación permitieron obtener durante el período 1991-2010, un BIAS de 5,5 %, SRMSE de 0,415 y NSE de 0,625 mejorando aún a lo obtenido durante calibración.

El comportamiento de las series temporales de HdS estimada y simulada, destacan la habilidad que presenta el modelo de superficie implementado para reproducir el comportamiento dinámico de las estimaciones de HdS, con valores de correlación de 0,608 y 0,754 en las etapas de calibración y validación respectivamente. Esta mejora es sustancial respecto a la correlación mostrada con la condición BASE de parámetros.

Capítulo 4

Climatología de Eventos Extremos Secos.

El Sudeste de Sudamérica es una región donde la agricultura y la ganadería constituyen los recursos principales que contribuyen al PBI (producto bruto interno) de la región. En Argentina las exportaciones primarias de productos agrícolas sumaron u\$86.000 millones en 2011, esto ha sido generado principalmente en la región pampeana y aportado por los tres principales cultivos de granos: la soja, el maíz y el trigo (Krishna, 2015). La mayor parte de la agricultura producida en la región Pampeana es de secano, el riego representa menos del 3% de la superficie total cubierta por el trigo, el maíz y la soja (ver Siebert et al., 2013). Esta situación origina que tanto la agricultura como la ganadería sean susceptibles a la variabilidad y a los extremos climáticos, ya que solo dependen de la lluvia natural. El maíz es uno de los cultivos más sensibles a los déficits de agua (Minetti et al., 2007), mientras que la producción de soja tiende a verse afectada por cualquiera de los extremos tanto húmedos como secos (Penalba et al., 2007). En consecuencia la ocurrencia de eventos extremos secos puede derivar en impactos económicos y sociales de magnitud en la región donde este evento suceda. La documentación de los eventos de sequía de los últimos años y sus impactos han ratificado esta afirmación. Numerando algunos de los eventos que ocurrieron en esta región de Sudamérica se identifican: por ejemplo la sequía de 1988/89 en Argentina que se fue clasificada entre los peores episodios de registro debido a su déficit de agua. Durante ese período la superficie cultivada se redujo en aproximadamente 35%, y el rendimiento de los cultivos en alrededor de 15%, resultando en una disminución de 44% de la productividad lo que ocasionó grandes pérdidas económicas (FMI, 1990). El evento de 2003/4 es otro ejemplo de un episodio seco con importantes daños, comenzó en septiembre de 2003 y en abril de 2004, la disminución del caudal del río Uruguay llevó al cierre de trece de las catorce turbinas en la represa hidroeléctrica de Salto Grande (Tirso Fiorotto, 2004; Penalba y Vargas, 2008). La sequía de 2008/9 fue en su momento el evento y más intenso de los últimos 50 años de registro (Skansi et al., 2008; Müller et al., 2014), con una baja en los rendimientos de trigo de alrededor del 50% y una mortalidad de 1,5 millones de bovinos en Argentina (Sheffield y Wood, 2012).

Un estudio llevado a cabo por Rivera y Penalba (2014) sobre las tendencias y patrones de las sequías en esta región de Sudamérica, indica que las tendencias lineales de precipitación en la segunda mitad del siglo XX presentan un incremento de la misma, esto mismo se ha destacado en Krepper y Zucarelli (2010), generando así una disminución de las condiciones de sequía en la región del SESA; no obstante las tendencias no lineales muestran una reversión de este comportamiento en la década del 90. En este sentido, hay estudios que aseguran que la tendencia de precipitación en los meses de verano en la primera parte del siglo XXI, va a disminuir en esta región (Junquas et al., 2012; Rivera y Penalba, 2014). En concreto para el presente siglo, Penalba y Rivera (2013 y 2016a) analizaron la proyección de las características de sequía para todo el siglo XXI utilizando un ensamble de modelos, y detectaron que los eventos secos a futuro serán de menor duración, pero más frecuentes y severos, en comparación con las propiedades de las sequías del período 1979-2008. Este resultado asegura un incremento en la variabilidad de la precipitación y por lo tanto, también, la necesidad de establecer un continuo monitoreo e interpretación de las condiciones imperantes.

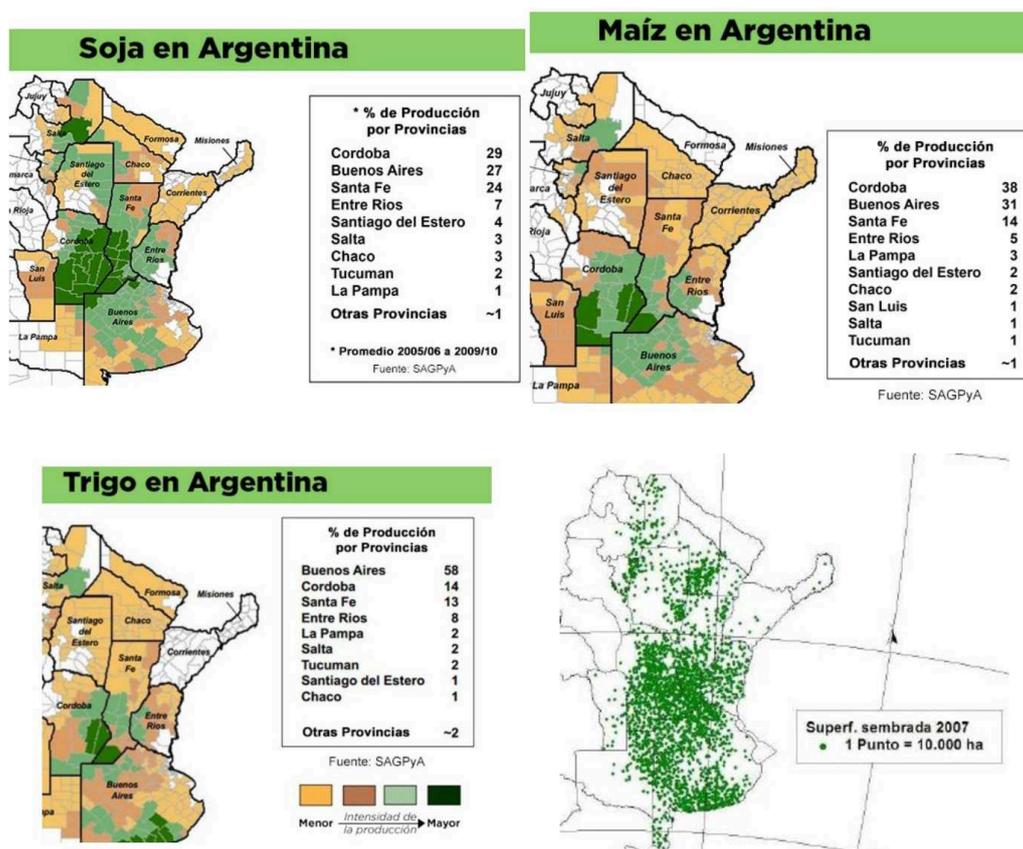


Figura 4.1: Regiones de mayor intensidad de producción en relación a cultivos de Soja, Maíz, y Trigo. En el panel final se muestra la distribución de superficie sembrada. Fuente: *news.agrofy.com.ar*. Cruzate y Casas (2012)

En el desarrollo del capítulo 2 se estableció una zona al sur de la cuenca del Plata coincidente con la región donde existe mayor intensidad de producción de los cultivos de trigo, maíz y soja, esa región se encuentra definida por las coordenadas de latitud $[-65^\circ, -59^\circ]$ y longitud $[-38^\circ,$

29°]. En la figura 4.1 se muestran las regiones donde cada cultivo presenta mayor intensidad de producción, en esta misma figura se visualiza también la densidad de superficie sembrada en el último panel, aportando una idea visual de cómo es la distribución espacial de producción. En esta región se produce aproximadamente el 80% del total de maíz, trigo y soja de toda Argentina, lo que representa el 60% del PBI del país (Hartmann et al., 2003). Esta región denominada zona 2 abarca principalmente parte de las provincias de Santa Fe, Entre Ríos y Córdoba, también una parte de Buenos Aires y una pequeña parte del norte de La Pampa, y de acuerdo con el último panel de la figura 4.1, contiene la mayor densidad de superficie de siembra. Los tres cultivos mencionados poseen diferentes ciclos fenológicos desde su plantación hasta que se logran cosechar, y tienen una duración de entre 7 y 9 meses. El trigo se planta durante la última parte del otoño o principios del invierno (mayo-junio), se cosecha durante el verano, y es más sensible a las necesidades de agua en el período de crecimiento que ocurren durante primavera (octubre-noviembre). En tanto que para los cultivos de maíz y soja, se los planta en la primavera (octubre-diciembre) y se cosechan en el otoño siguiente, siendo los meses de verano de diciembre a febrero el período de mayor necesidad de agua.

Este trabajo avanza en la determinación de las propiedades físicas de los eventos secos que se registran en la región de zona 2. En esta etapa se enumeran las características principales vinculadas a los eventos extremos secos, estas propiedades físicas de las sequías las constituyen el análisis de frecuencia, la duración, la severidad, y la extensión areal de eventos seco detectados. Este análisis considera, como primer paso, la determinación de índices estandarizados que corresponden a las variables de superficie que muestran sensibilidad a la ocurrencia de eventos secos, las que ya han sido estudiadas en el capítulo 3. Posteriormente a esta determinación se define un umbral propio en cada indicador que lleva asociado al mismo una definición única de sequías; y a partir de estos umbrales quedan definidos y separados eventos secos de no secos. El uso de diferentes variables en la determinación de los indicadores permite asociarlos con distintos tipos de sequías. Esta metodología aquí presentada orientada exclusivamente al estudio de los eventos secos, también puede ser usada para caracterizar eventos extremos húmedos.

4.1. Tipos de Sequías y Variables.

La disponibilidad de agua la controla el sistema físico y las demandas responden a las necesidades del sistema biológico (Redmond 2002). Cuando el sistema biológico tiene demandas que el sistema físico no puede abastecer, por ausencia total del recurso o bien por déficit del mismo, se dice que existe un evento seco. Desde este punto de vista físico, las sequías se caracterizan como meteorológicas cuando el déficit se refiere a la precipitación, cuando el déficit es del contenido de humedad del suelo la sequía se denomina agrológica y durante este tipo de sequías los cultivos no pueden obtener agua del suelo (Wilhite, 2016). Mientras que si la escorrentía se encuentra por debajo de un nivel determinado, la sequía que existe se denomina hidrológica (ver por ejemplo, Dracup et al., 1980). En función de esta definición de tres tipos de sequías,

se considera a las simulaciones de humedad del suelo, de escorrentía, y de evapotranspiración, además de la precipitación que constituye un forzante, para utilizarlas en la construcción de los indicadores estandarizados que permitirán evaluar y clasificar a los eventos secos.

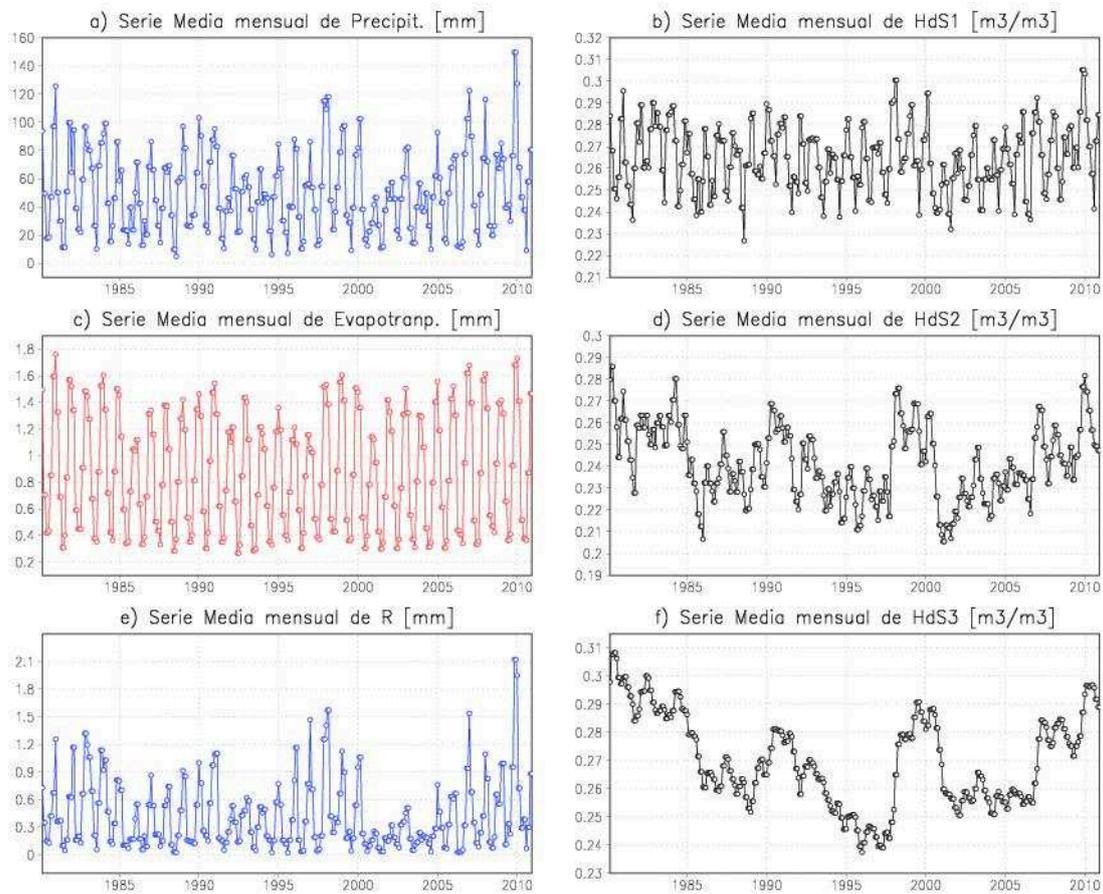


Figura 4.2: Series temporales a paso mensual de la cuenca del Plata durante el período 1980-2010 de las variables simuladas. a) Precipitación, b) Humedal del suelo en capa 1, c) Evapotranspiración, d) ídem b en capa 2, e) Escorrentía, y f) ídem b en capa 3.

Los campos de las variables utilizadas en la construcción de los indicadores se generaron a través de la simulación durante el período 1980-2010, utilizando el set 4 de parámetros de suelo, y se procedió de la siguiente manera: para reducir el *spin-up*, o tiempo de estabilización estadístico del modelo en relación con los forzantes, se comenzó una simulación en frío (*cold start*) es decir sin datos del estado previo (*state file*) que caracterice la situación del sistema. Primeramente se realizó una simulación-A para el período 1980-2010 a paso 6-horario generando un *state file - A* al final del período de simulación, que luego se usó para comenzar una simulación-B (*warm start*) del período 1980-82 generando un segundo archivo del estado del sistema, *state file - B*, de ese período. Finalmente se realizó una simulación-C inicializada con el *state file - B* con el que se obtuvo un *state file - C* del período 1980-2010. Con esta última simulación se generaron 31 años de datos simulados a paso diario de las variables hidroclimáticas de superficie más sensibles a la sequía. Se determinaron los valores mensuales de cada una de las variables para toda la cuenca y se graficaron las series temporales medias de la cuenca del Plata, como se puede ver en la figura 4.2.

Las variables precipitación, evapotranspiración y escorrentía se encuentran expresadas en valores de [mm], como se obtienen de la salida del modelo, mientras que las variables de humedad del suelo se expresan en [$m^3 m^{-3}$] una vez que han sido divididas por el espesor en [mm] de cada capa. Algunas variables simuladas como la HdS_1 y evapotranspiración presentan una rápida variación temporal, evidenciando una rápida respuesta en relación a la disponibilidad de agua en superficie, como se ve en las series temporales de la figura 4.2b) y c) respectivamente. Otras variables muestran una variación más suavizada y lenta, como la HdS_2 por tener un espesor de la capa de suelo intermedio mayor que la capa superficial, y además por ubicarse debajo de esta, esto también ocurre con la escorrentía R , figura 4.2d) y e). Finalmente La HdS_3 presenta la variación temporal más lenta de las variables analizadas, se aprecian períodos con descensos y recuperaciones más prolongados, ocasionando un retraso en la respuesta de esta variable en relación a la precipitación, y asociando a HdS_3 con eventos de menor variabilidad temporal. El grado de vinculación entre las variables de superficie (P , Evt , R y HdS_1 , HdS_2 y HdS_3), y los indicadores SPI3, SPI6, y SPI9, se determinó mediante el coeficiente de correlación (r) y los valores de los mismos se muestran en tabla 4.1. En la misma aprecia que la correlación de los índices mejora los valores de los coeficientes obtenidos entre las propias variables.

	SPI3	SPI6	SPI9	P	Evt	R	HdS_1	HdS_2	HdS_3
SPI3	1	0,81	0,76	0,61	0,09	0,54	0,55	0,73	0,71
SPI6	-	1	0,92	0,52	0,13	0,56	0,57	0,71	0,64
SPI9	-	-	1	0,5	0,15	0,52	0,52	0,67	0,6
P	-	-	-	1	0,19	0,23	0,18	0,34	0,35
Evt	-	-	-	-	1	0,17	-0,19	-0,12	-0,17
R	-	-	-	-	-	1	0,65	0,47	0,42
HdS_1	-	-	-	-	-	-	1	0,65	0,38
HdS_2	-	-	-	-	-	-	-	1	0,78
HdS_3	-	-	-	-	-	-	-	-	1

Cuadro 4.1: Coeficientes de Correlación entre series temporales de Indicadores de escalas de 3, 6 y 9 meses, y variables de superficie P , Evt , R , HdS_1 , HdS_2 y HdS_3 , correspondientes a la zona 2.

Los indicadores SPI3, SPI6 y SPI9 son los que presentan mejores correlaciones con el resto de las variables, con coeficientes (r) entre 0,5 y 0,7, excepto con Evt para la cuál son muy bajos. Destacándose un valor de (r) = 0,73 entre SPI3 y HdS_2 , y de (r) = 0,71 entre la misma variable y SPI6, los coeficientes para SPI9 son ligeramente más bajos. Se destaca un aumento de los coeficientes cuando la correlación es entre los propios índices, con valores de (r) entre 0,76 y 0,92. Entre las variables, los valores de correlación con Evt son muy bajos del orden de (r) = 0,1, esto indica la poca vinculación que presenta con el resto de las variables e indicadores. La variable P también presenta bajos valores de correlación (r) = 0,2 a 0,3; y el resto de las variables tienen un valor de correlación más alto destacándose entre ellas la HdS_2 . Los valores de correlación resultan ser más bajos en las variables de mayor variabilidad temporal y los coeficientes de correlación muestran un incremento en sus valores cuando la variable tiene un comportamiento temporal más suavizado.

4.2. Indicadores Estandarizados.

La construcción de los indicadores para cada una de las variables se realizó utilizando la metodología no paramétrica ya utilizada en el capítulo 2 para la variable precipitación, esta metodología denominada SDAT (*Standard Drought Analysis Tool*, en inglés) desarrollada por Hao y AghaKouchak (2014) y Farahmand y AghaKouchak (2015). Este esquema se aplica a las variables simuladas de superficie para la determinación de los índices estandarizados, y así poder abordar el estudio de la sequía desde un enfoque de múltiples variables. Utiliza una función empírica basada en Gringorten (1965) determinada en función de la probabilidad de ocurrencia de cada variable, utilizando la expresión 1 del capítulo 2 para su determinación. Siguiendo con este marco metodológico y los procedimientos desarrollados en la estimación de los SPI, se determinan indicadores estandarizados para las nuevas variables. Como la estimación de los índices requiere que los datos de las variables sean mensuales, previamente se transformaron los datos diarios de las variables en mensuales. Para el caso particular de humedad del suelo se sumo el contenido de cada una de las 3 capas, a fin de considerar el contenido de humedad total, de esta forma la variable refiere al contenido de humedad en las 3 capas de suelo en forma conjunta, HdS_1 , HdS_2 y HdS_3 .

A través de la metodología detallada se obtuvieron los datos de SPI, SSI, SEI, y SRI que constituyen individualmente los indicadores estandarizados de Precipitación, Humedad del Suelo, Evapotranspiración y Escorrentía respectivamente. Como el cálculo de estos indicadores requiere al menos 30 años de datos mensuales para una estimación confiable, se utilizó el período completo de simulación 1980-2010 en su determinación para toda la cuenca con una resolución horizontal de $0,125^\circ \times 0,125^\circ$. Considerando que las escalas de tiempo más cortas del indicador pueden destacar la estacionalidad y asociarse con sequías meteorológicas y agrológicas, mientras que las escalas más grandes reflejan mejor la sequía hidrológica (Penalba y Rivera, 2016b). Las escalas temporales de trabajo sobre las cuales se construyeron los indicadores son 3, 6 y 9 meses con el objeto de identificar las distintas características de las sequías. Por otro lado, las escalas de 3 y 6 meses coinciden con la duración de los eventos secos más comunes en esta región del país, a estas dos escalas se le agrega la de 9 meses para estudiar su vinculación con los eventos detectados cuando se requiera.

La naturaleza de los índices permite realizar comparaciones consistentes entre valores del índice en diferentes locaciones (Keyantash y Dracup 2002), es decir por ejemplo dos valores iguales del indicador, uno en la mesopotamia Argentina y otro en la llanura Pampeana, representan la misma probabilidad de ocurrencia de un evento, aunque estén asociados a valores diferentes de precipitación, ya que la estandarización del índice se hace respecto a los datos propios de la variable en esa misma locación. El valor del SPI representa la anomalía estandarizada de la precipitación y se encuentra entre los índices más utilizados para cuantificar y monitorear sequías de origen meteorológico, así como también para determinar su severidad (Keyantash y Dracup 2002, Mishra et al 2009, Hayes et al., 2011). Los valores de SPI3 reflejan condiciones

secas de corto período, mientras que SPI6 y SP9 lo hacen a condiciones de más largo plazo como por ejemplo variaciones estacionales, e indican también el inicio de descensos en los niveles de los reservorios, que usualmente presentan escalas de tiempo mayores que la precipitación (Lloyd-Hughes y Saunders, 2002). La naturaleza estandarizada hace que el comportamiento del índices tenga asociada una función de distribución Normal (ver por ejemplo, McKee et al., 1993), con valor medio (\bar{x}) = 0 y desvío estándar (σ) = 1. Luego existe una probabilidad del 34/100 que los valores del índice se encuentren en un rango entre el valor medio y un desvío estándar (1σ), de $\sim 48/100$ a que se encuentren entre valor medio y 2σ , y de $> 49/100$ a que se encuentren entre el valor de y 3σ . El valor de probabilidad asociado al índice se relaciona con el nivel de recurrencia del evento, por ejemplo, decir que existe una probabilidad de 16/100 a que un evento sea menor que -1σ , es equivalente a decir que ocurren 16 eventos de este tipo en 100 años, o que existe una probabilidad de 0,16 a que el evento ocurra al menos una vez en 100 años. También las frecuencias de ocurrencias de eventos extremos, determinadas a través de índices estandarizados, entre diferentes locaciones son consistentes (Hayes et al., 1999, Keyantash y Dracup 2002). En McKee et al., (1993) se estableció una forma para caracterizar el tipo de evento extremo según el valor del índice estandarizado de precipitación, como se ve en tabla 4.2 los valores del rango negativos del indicador se relacionan con eventos que van desde cercano a lo normal hasta extremadamente seco.

Categorías de Sequías	Valores de SPI
Cercano a lo Normal	-0,99 a 0,99
Moderadamente Seco	-1,00 a -1,49
Muy Seco	-1,50 a -1,99
Extremadamente Seco	-2,00 y <

Cuadro 4.2: Clasificación de eventos extremos de acuerdo a valores de SPI.

Para la caracterización de los eventos secos, en esta tesis, se utiliza el umbral igual a -1σ (un desvío estándar negativo), definiendo así eventos secos (moderados a extremadamente secos) de los no secos, y también sus características inherentes (Yevjevich, 1967), como duración, severidad, frecuencia, y extensión areal.

Se define un evento seco como aquel que presenta un valor del índice menor o igual al umbral, como se ve en la figura 4.3 en donde el umbral es X_0 y que de acuerdo a este trabajo será de -1 . De esta manera un valor del índice menor o igual a -1 (equivalente a 1σ un desvío estándar negativo) se considerará como evento seco y todo lo que sea mayor a -1 será no seco. Utilizando este valor de umbral los eventos secos determinados corresponden a sequías moderadas a extremas como lo indica la tabla 4.2; en la figura 4.3 se aprecia que características de la sequía, como la duración (n) y la severidad (S_n) se encuentran asociadas con el valor de umbral establecido.

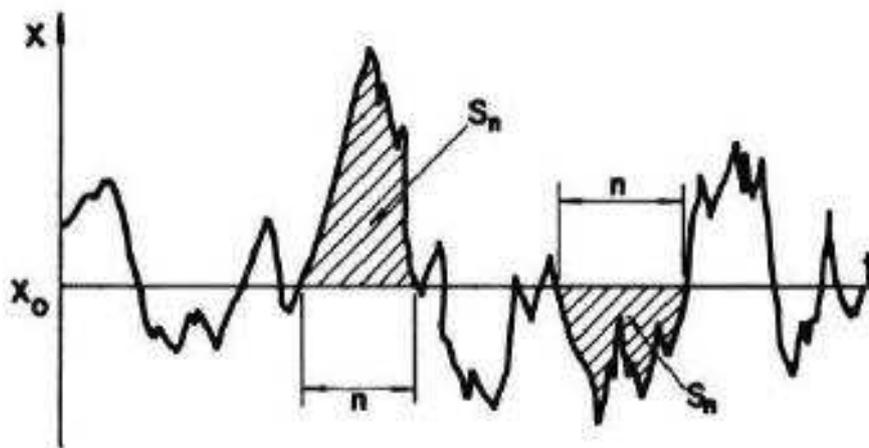


Figura 4.3: Definición de evento seco mediante el uso de umbral. Tomado de Yevjevich, 1967.

4.3. Climatología de Sequías.

En la climatología de sequías se analiza estadísticamente a los fenómenos secos ocurridos, determinando sus características como: Frecuencia (F), es decir la cantidad de veces que ocurre uno de estos eventos en el lapso de tiempo de análisis, la Duración (D) se refiere al tiempo que se prolonga un evento seco detectado, también desde el punto de vista del análisis de la marcha del índice, equivale al tiempo entre dos eventos no secos sucesivos. La severidad (S) se determina como el producto entre la magnitud del evento seco y su duración, es equivalente al déficit acumulado de agua durante el período que dure la sequía (Dracup et al., 1980). Por último la Extensión Areal (E) del evento seco, corresponde al área que ocupa el evento definido y sobre el cual se extendió. Todas estas características son inherentes al evento seco y son únicas para el umbral que lo define.

4.3.1. Frecuencias.

La figura 4.4 muestra la distribución de frecuencias para el sur de la cuenca del Plata de los eventos detectados que son menores o iguales al umbral, para cada indicador de 3 y de 6 meses. Este valor de frecuencias se obtuvo contabilizando la cantidad de eventos menores al umbral -1, durante los meses que contiene el período 1980-2010; expresados en valor de probabilidad, es decir dividiendo la frecuencia obtenida entre el total de casos posibles. Entonces para los indicadores de 3 meses el total de casos posibles es de 370 porque para los meses 1 y 2 el índice de 3 meses no está definido, de forma análoga para indicadores de 6 meses el total de casos posibles es de 367. De esta manera una probabilidad hipotética igual a 1 implica que durante el total de casos posibles se registraron eventos menores o iguales al umbral.

Los valores de probabilidad que muestra la figura 4.4 varían entre 0,1 y 0,19 en toda esta región de la cuenca. Todos los paneles de la misma coinciden en destacar a la parte norte de esta región, zona limítrofe entre Argentina, Brasil y Paraguay, como la región donde existe

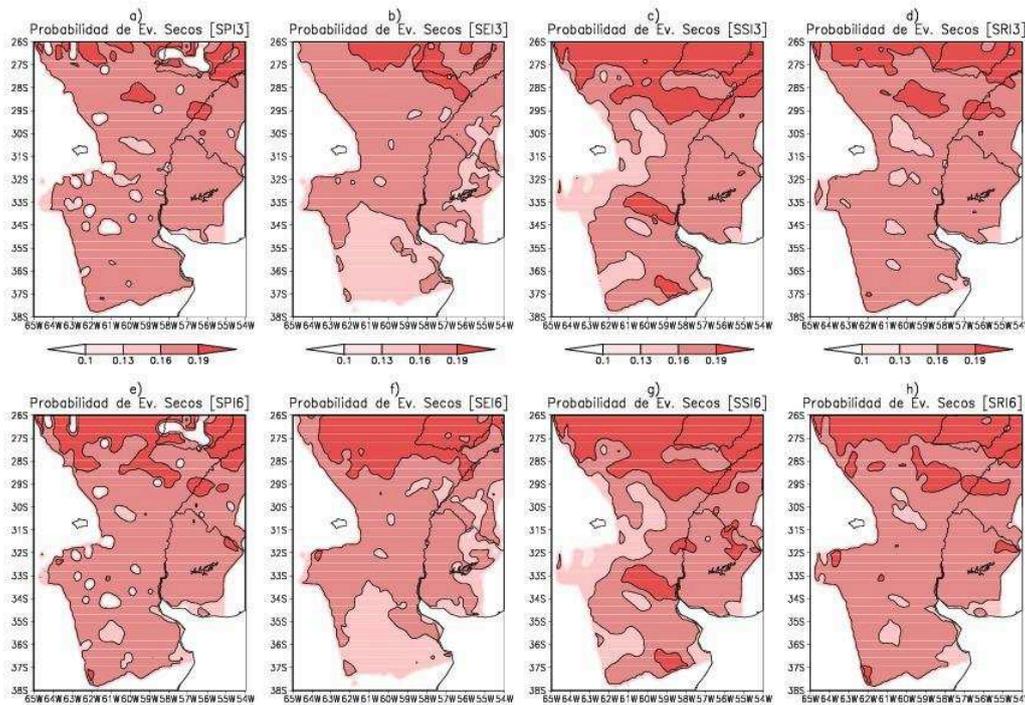


Figura 4.4: Probabilidad de ocurrencia de eventos menores al umbral durante el período 1980-2010, de acuerdo a indicadores de 3 meses a) SPI3, b) SEI3, c) SSI3, y d) SRI3; e), f), g) y h) ídem para indicadores de 6 meses.

mayor probabilidad de ocurrencia de sequías de este tipo con una probabilidad de ocurrencia 0,19. Sobre la parte sur la probabilidad disminuye hasta 0,16, excepto para en el índice SEI que muestra zonas con valores de 0,13 en ambas escalas de tiempo (figs. 4.4b) y f)). Valores similares se muestran también para SSI, pero este último indicador presenta además probabilidades de 0,19 sobre parte de Buenos Aires, Santa Fe y Entre Ríos.

En figura 4.5 se muestran series de tiempo de frecuencias de eventos secos acumuladas para indicadores con escalas de tiempo de 3, 6 y 9 meses en zona 2. Esto representa cómo se acumulan temporalmente las frecuencias durante el período de análisis de acuerdo a cada indicador. Los 4 paneles establecen un marcado incremento en sus frecuencias en la segunda mitad de la década de 1990, cuando se produjo un marcado crecimiento de la cantidad de eventos detectados del orden de 20 en menos de 5 años. Otros incrementos destacados, aunque de una magnitud menor, se produjeron en 1988/89 y también en 2008/9; cada uno de estos incrementos se produjo en coincidencia con las principales sequías destacadas al inicio del presente capítulo. Para las series temporales del indicador SSI, prácticamente no existen diferencias apreciables en las diferentes escalas de tiempo del indicador; mientras que para las series de SEI se presenta el caso opuesto. Esto determina que tanto menor sea la variabilidad temporal que presenta el indicador, menor será la variación de las frecuencias acumuladas en las distintas escalas temporales del mismo índice.

La figura 4.6 presenta los histogramas de frecuencia de indicadores de 3 meses en color verde y de 6 meses en azul para zona 2. Cada histograma muestra cómo es la distribución de las

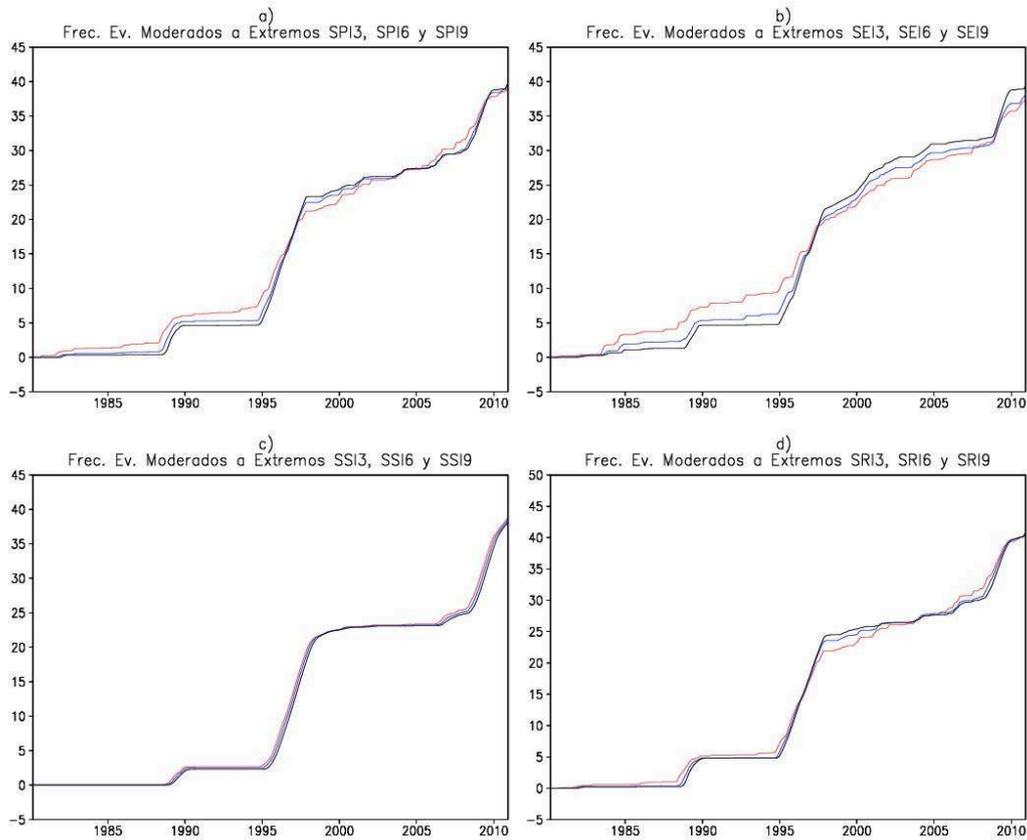


Figura 4.5: Series de tiempo de frecuencias acumuladas según indicador en zona 2: a) SPI3 (rojo), SPI6 (azul) y SPI9 (negro), b) ídem a) para SEI, c) ídem a) para SSI, y d) ídem a) para SRI.

frecuencias agrupadas por intervalos de acuerdo a su valor, donde los intervalos para un indicador estandarizado cualquiera comienzan en -3 tienen un ancho fijo de $0,5$ y finalizan en 3 , como se puede ver en los paneles de la figura. La máxima frecuencia la presenta el indicador SPI tanto de 3 como 6 meses en las figuras 4.6a) y e) con un valor de 140 y 160 respectivamente, y en ambos casos ocurre en el intervalo $(0,5\sigma; 1\sigma)$. Este indicador además presenta una distribución de las frecuencias con mayor concentración sobre los intervalos centrales. Opuesto a esto, el resto de los indicadores presentan valores de frecuencias que abarcan una mayor cantidad de intervalos, con una distribución más asimétrica y donde las mayores frecuencias se encuentran del lado negativo del indicador.

Los histogramas de SSI3 y SRI3, en las figs. 4.6d) y e), al igual que para SPI3 coinciden en tener la frecuencia más alta en los intervalos positivos, pero más cerca del valor central $(0; 0,5\sigma)$, mientras que para SEI3 la máxima frecuencia se produce en el intervalo $(-0,5\sigma; 0)$. Estos indicadores, con excepción de SPI3 presentan mayores frecuencias en los intervalos negativos que en los positivos, manifestando una mayor probabilidad de ocurrencia de eventos secos que no secos. Los indicadores con escala temporal de 6 meses muestran frecuencias máximas levemente menores que los de 3 meses, excepto para SPI6 que presenta un leve incremento en el mismo intervalo $(0,5\sigma; 1\sigma)$ respecto a SPI3. Se mantiene en esta escala de tiempo mayores frecuencias agrupadas del lado de los intervalos negativos respecto a los positivos, sosteniendo

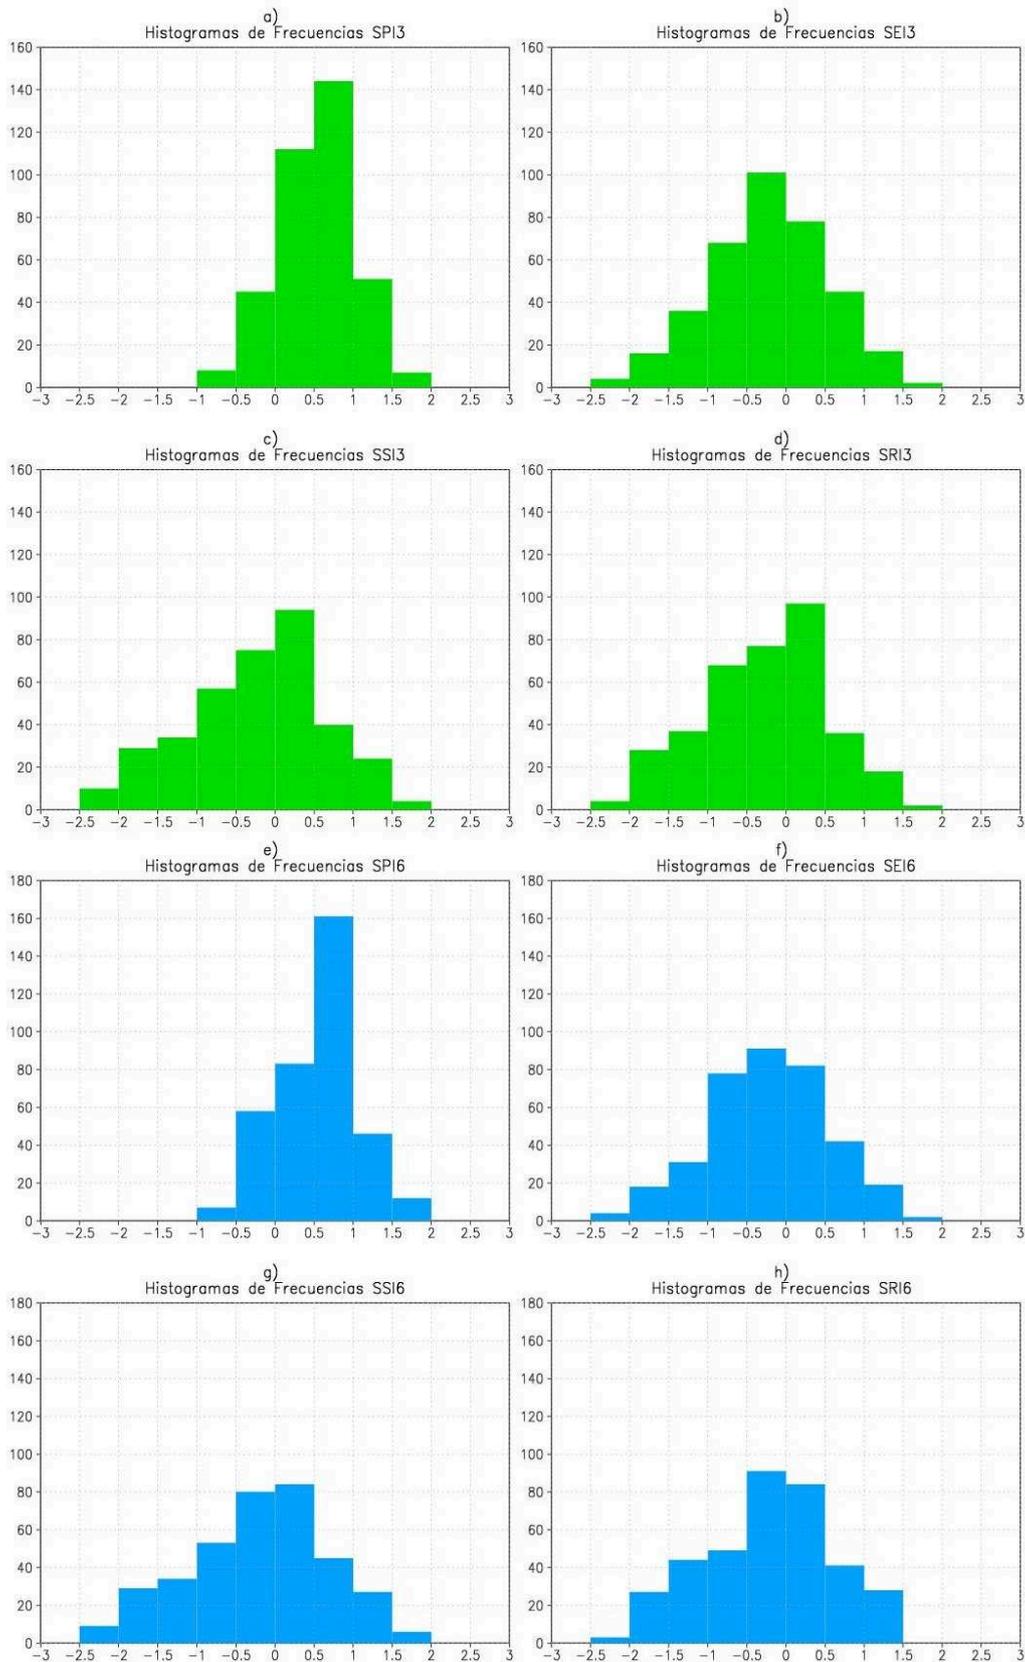


Figura 4.6: Histograma de Frecuencias en zona 2 para indicadores de 3 meses en verde, a) SPI3, b) SEI3, c) SSI3 y d) SRI3; y para indicadores de 6 meses en azul, e) SPI6, f) SEI6, g) SSI6 y h) SRI6.

la mayor probabilidad de ocurrencia de eventos secos.

4.3.2. Duración.

La duración de un evento seco, que como ya se estableció corresponde al tiempo entre 2 eventos no secos sucesivos; también se destacó que al utilizar un umbral para definir los tipos de eventos, no solo se separan los eventos secos de los no secos sino también se definen otras características inherentes a los mismos como son la duración, la magnitud y severidad. Utilizando el umbral igual a -1, la figura 4.7 presenta la cómo es la distribución de la frecuencia de eventos secos en función de su duración en zona 2. En la misma se muestran histogramas de cantidad de eventos detectados según cada duración. Las duraciones analizadas van desde sequías de 1 mes hasta sequías de 15 meses, evaluadas mediante los indicadores SPI, SEI, SSI, y SRI de escalas temporales de 3 meses en color naranja y de 6 meses en entramado.

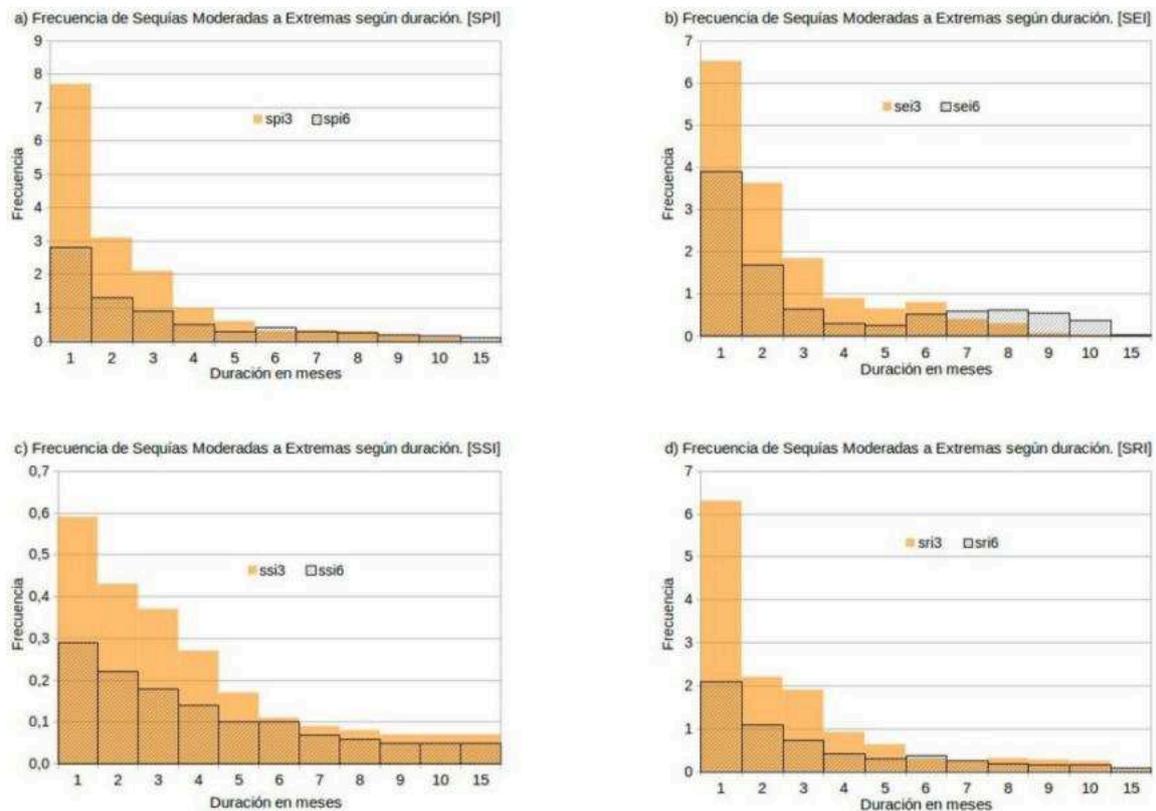


Figura 4.7: Histogramas de Frecuencias de sequías moderadas a extremas en zona 2, de acuerdo a diferentes duraciones. a)SPI3/6, b)SEI3/6, c)SSI3/6, y d) SRI3/6.

Según su duración las sequías pueden ser de corto, mediano o largo plazo, en este caso se considera que las sequías con duraciones entre 1 mes y 3 meses son de corto plazo, las que persisten de 8 meses en adelante son de largo plazo y las que se prolongan entre 4 y 7 meses son de mediano plazo. Se puede advertir por su frecuencia que todos los paneles de la figura 4.7 destacan que las sequías que se producen en esta zona son principalmente de corto plazo, también existe evidencia de eventos de mediano plazo y hasta de largo plazo, aunque mínima en

este último caso. Los valores de frecuencias máximas se ubican por debajo de la decena según SPI3, SEI3, y SRI3, mientras que SSI3 presenta valores mucho menores que el resto; esto es indicativo de que la menor variabilidad del indicador afecta en el número de sequías detectadas para cada duración.

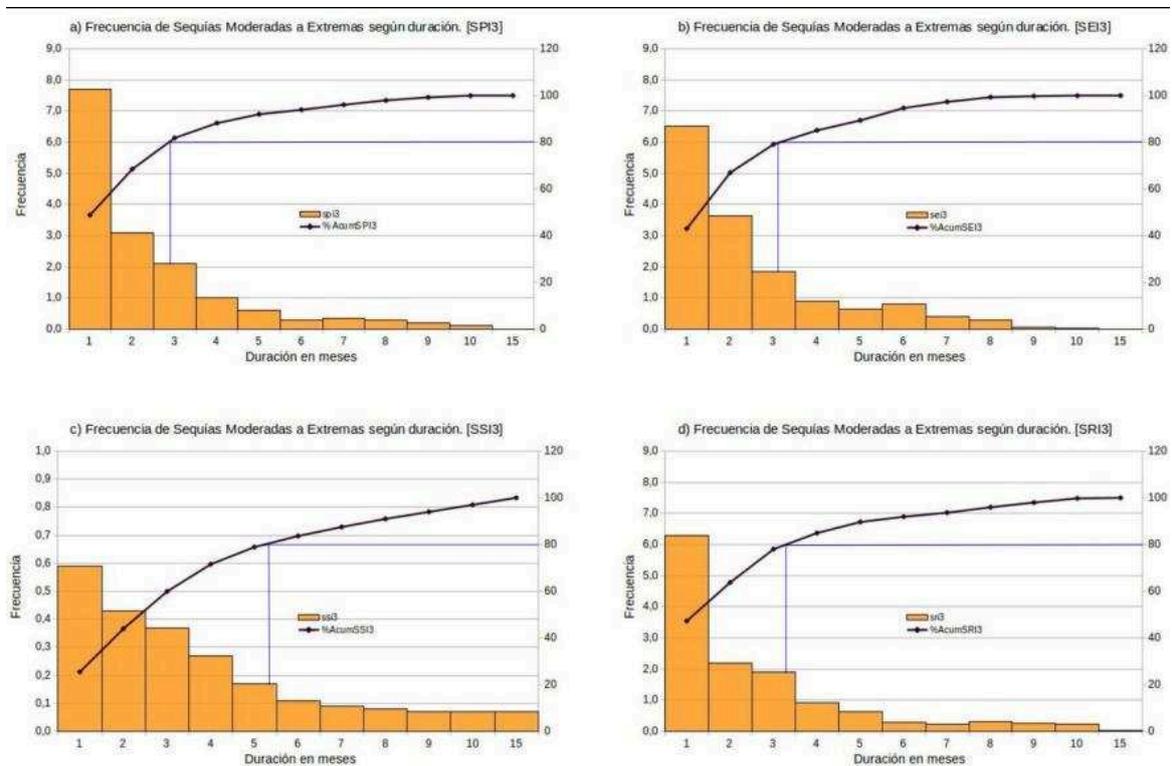


Figura 4.8: Diagramas de Pareto para índices de 3 meses. a) SPI, b)SEI, c) SSI, d) SRI.

Según los índices de 3 y 6 meses los eventos secos más frecuentes tienen una duración 1-mes en zona 2. Las frecuencias disminuyen en forma escalonada y su disminución es más suave cuando aumenta la escala de tiempo del indicador. Las sequías de más de 4 meses son poco frecuentes en zona 2. En general, por su naturaleza menos fluctuante los indicadores de 6 meses presentan frecuencias menores que los de 3 meses en sequías de corto plazo, pero este comportamiento se revierte cuando las sequías son de largo plazo. Esto es evidente en el panel 4.7 b), aún cuando las frecuencias sean bajas, los valores de SEI6 son mayores que SEI3 a partir de duraciones de 7 meses; además en los paneles a) y d) de la figura existe igualdad de frecuencia luego de los 6 meses de duración para ambas escalas de tiempo del índice. Todos los indicadores analizados coinciden en destacar que las sequías de 1 a 3 meses de duración presentan las frecuencias más altas de la zona (Figuras 4.7a-d). Estos resultados reflejan consistencia con lo expresado en Minetti et al. (2007) para la Pampa Húmeda en Argentina.

Una manera útil de medir el potencial impacto que presentan los eventos secos en esta región del país y establecer de igual forma la duración de las sequías que mayores consecuencias provocan; es mediante un análisis de diagramas de Pareto utilizando el concepto que establece que el 80% de los impactos ocasionados es provocado por solo el 20% de las causas (Juran y Gryna, 1970). Es por eso que a continuación en las figs. 4.8 y 4.9 se muestran diagramas de Pareto

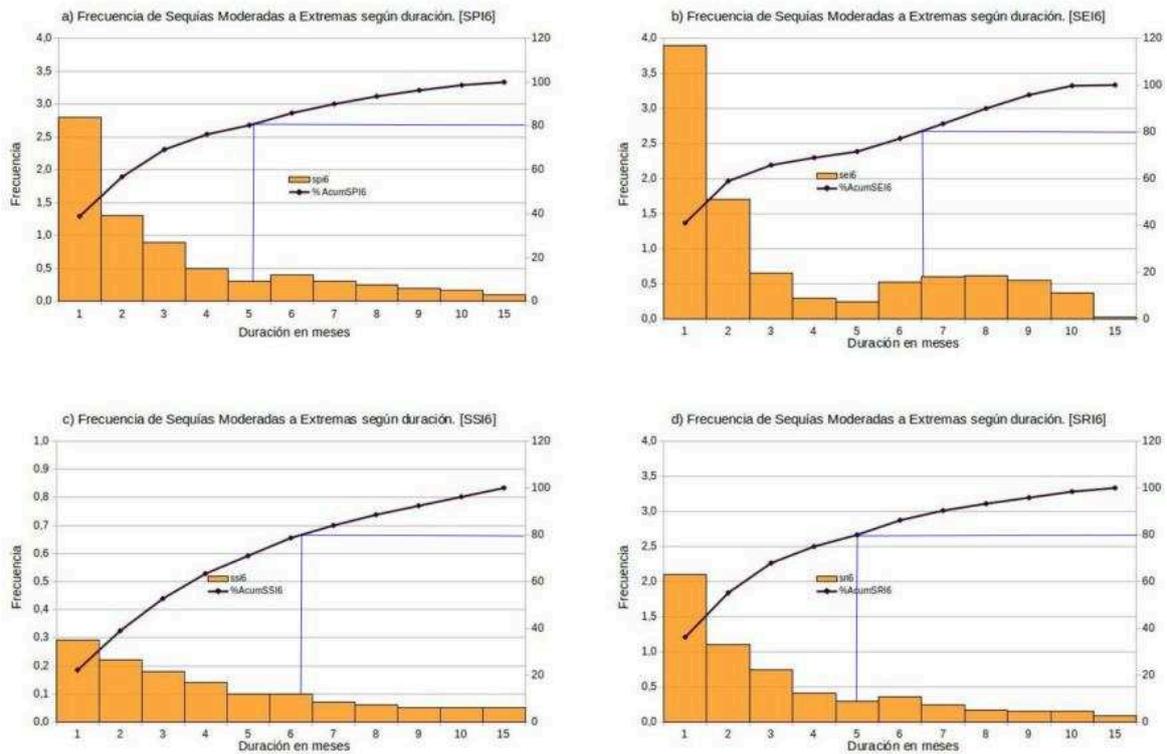


Figura 4.9: Ídem figura 4.8 para índices de 6 meses.

construidos sobre los histogramas de frecuencias de las sequías, a los que se les agrega una curva de frecuencia acumulada de sequías de acuerdo a cada duración. En cada panel de las figuras ingresando con el valor de la frecuencia acumulada del 80 %, cuando se intercepta la curva de frecuencia acumulada se obtiene el valor asociado de duración que corresponde al 20 % de las sequías que mayor impacto produce. Se destacan las sequías de 3 meses como las que producen el 80 % de los impactos, según las figs. 4.8a), b) y d), mientras que solo para el indicador SSI3 ocurre en las sequías de 5 meses. Cuando los índices tienen escala de 6 meses las sequías de mayor impacto tienen una duración un poco mayor, en general entre 5 y 6 meses, coincidiendo con la escala de tiempo del indicador. La figura 4.7 enfatiza en promedio las frecuencias de los eventos secos según la duración del mismo, en toda la región de la zona 2. En rigor esto indica un valor promedio durante el período de análisis, sin embargo resulta útil determinar espacialmente cuál es la región, si existe, donde los eventos secos se producen con mayor frecuencia en la misma. En consecuencia en la figura 4.10 se presentan distribuciones espaciales de las mayores frecuencias de eventos de 1 mes y 2 meses de duración para los índices SPI, SEI, SSI y SRI de 3 meses; para los respectivos índices de 6 meses se muestran en la figura 4.11.

Siguiendo con el comportamiento mostrado en los histogramas, en ambas figuras se detecta que al aumentar la escala de tiempo del indicador de 3 a 6 meses, figs. 4.10 y 4.11 respectivamente, las frecuencias de las sequías se reducen; de igual forma se observa cuando el tiempo de la sequía se incrementa de 1 mes a 2 meses. La distribución espacial muestra que las frecuencias más altas de las sequías de duración 1 mes se producen hacia el este de la región, figura 4.10a)-d), concretamente la zona limítrofe entre Argentina, Uruguay y Brasil. Mostrando esta región las frecuencias más altas de todos los indicadores de 3 meses, con un valor de 12, excepto para

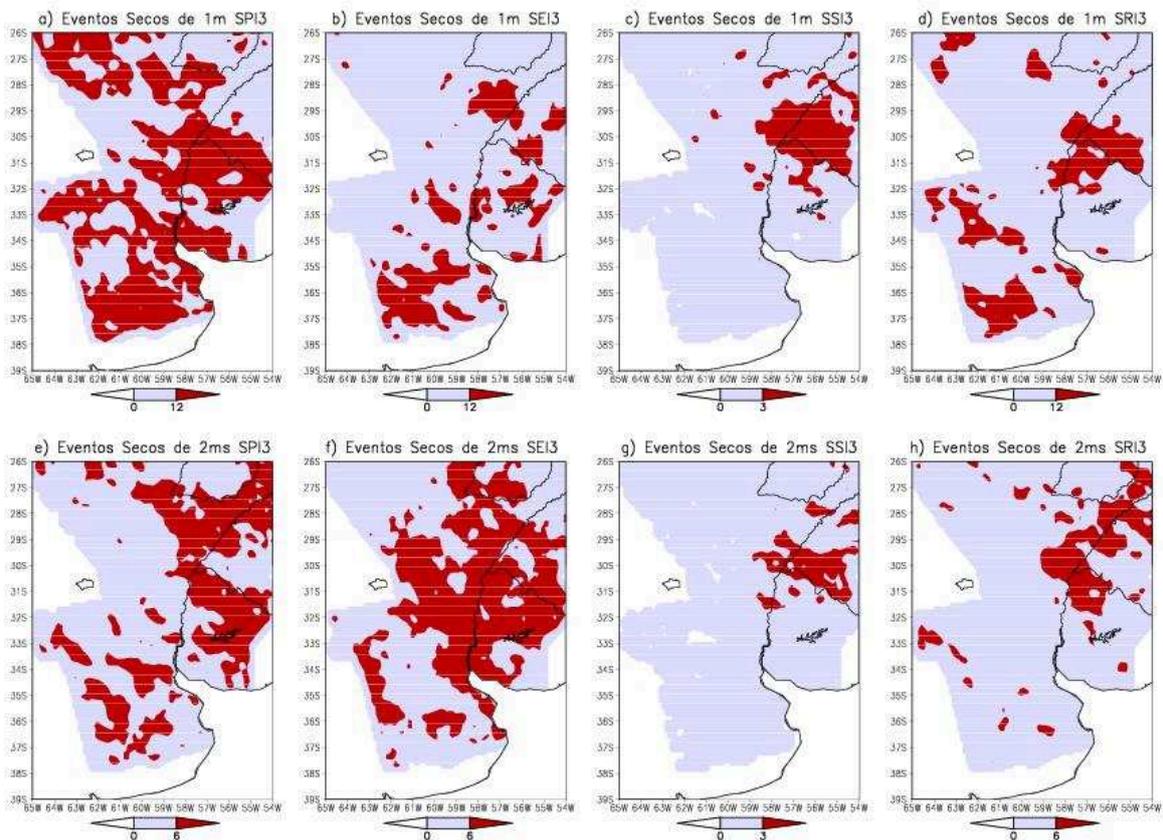


Figura 4.10: Distribución espacial de las mayores frecuencias de eventos secos, para 1 mes de duración: a)SPI3, b)SEI3, c)SSI3, y d)SRI3. Para de 2 meses de duración: e)SPI3, f)SEI3, g)SSI3, y h)SRI3

SSI3 donde el máximo es 3. La región del sur de la cuenca del Plata, centro de Bs. As., presenta frecuencias similares de 12 eventos para SPI3, SEI3 y SRI3; también para SPI3 en el norte de la región, en partes de Corrientes, Chaco y Formosa. En coincidencia estas mismas regiones muestran las mayores frecuencias para eventos de 2 meses de duración, como se observa en los paneles e), f) y h), con una extensión más reducida que para eventos de duración 1 mes, y con una frecuencias de 6. Los paneles c) y g) que corresponden al índice SSI no muestran diferencias notables entre sí, y solo se aprecia una región más reducida para los eventos de mayor duración. Para los indicadores de 6 meses en la figura 4.11 los valores de frecuencias de eventos secos son menores que en la figura 4.10, y las zonas con mayores frecuencias resultan coincidentes con las detectadas para los indicadores de 3 meses, aunque estas regiones se encuentran reducidas.

4.3.3. Severidad y Extensión Areal.

La severidad de un evento seco representa un déficit acumulado en el tiempo que dura el mismo, indicando que cuanto mayor sea el déficit más severo será el evento (Byun y Wilhite, 1999). En este trabajo el déficit se evalúa a través de los 4 indicadores presentados SPI, SEI, SSI y SRI, luego en relación a la variable que el índice evalúa, el déficit acumulado puede ser de precipitación, de humedad del suelo, de escorrentía o de evaporación. La forma en que se

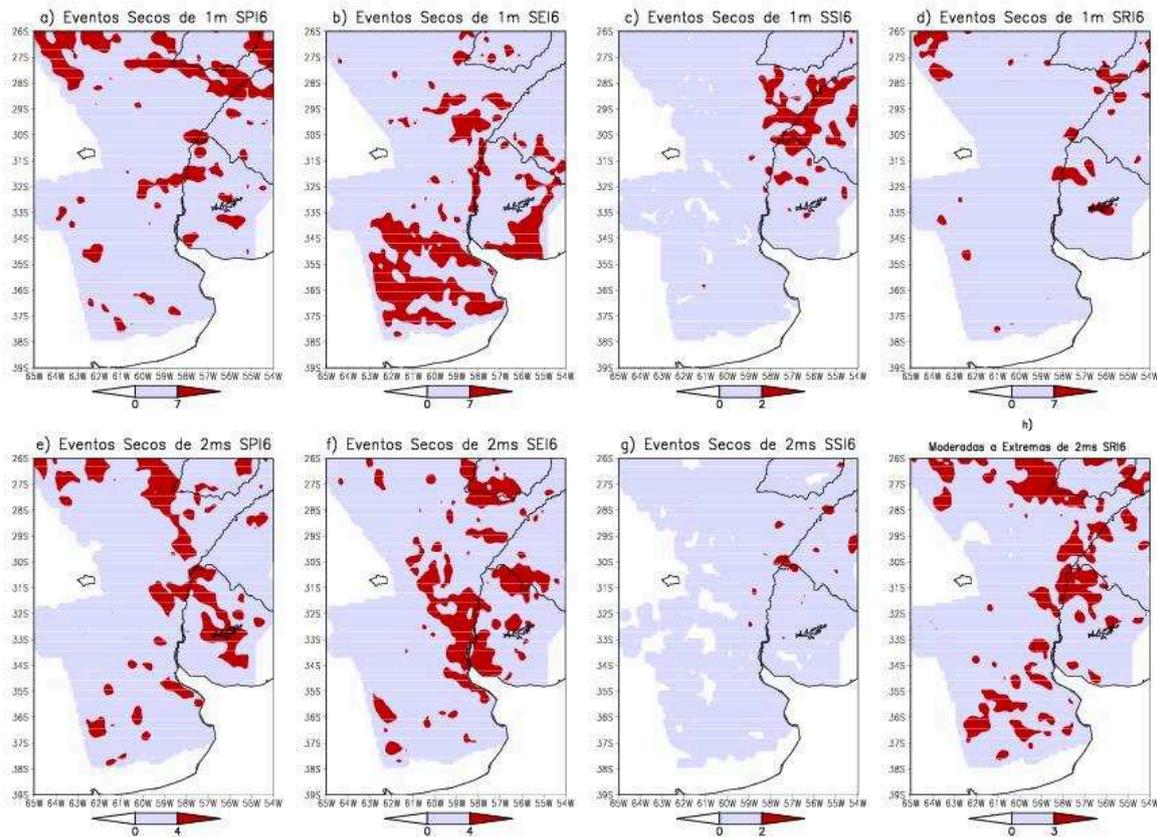


Figura 4.11: Ídem figura 4.10 pero con indicadores de escala de tiempo 6 meses.

cuantifica la severidad es mediante el producto entre duración y magnitud, es decir cada vez que se detecta un evento menor al umbral -1 se determina durante cuánto tiempo se prolonga el evento detectado y qué magnitud tuvo (Keyantash y Dracup, 2002). La magnitud se determina a través del valor medio de deficiencia durante el evento y haciendo el producto entre duración y magnitud se obtiene el valor de severidad. La extensión areal se determina contabilizando la cantidad de celdas de la grilla, dentro de zona 2, en las cuales se produjo al mismo tiempo un evento por debajo del umbral -1 , luego para cada evento detectado se estima su extensión areal y se expresa en $[km^2]$. El valor del área que abarca el evento se pondera por el coseno del ángulo de latitud para corregir el área debida a la curvatura de la tierra.

Las series de tiempo de severidad para zona 2, determinada a través de los diferentes indicadores se muestra en la figura 4.12. Como los valores de magnitudes de los déficits se encuentran por debajo del umbral -1 , esto implica que las magnitudes de las sequías sean negativas y como la duración es un valor positivo esto convierte a los valores de severidad en negativos. De esta forma las series de tiempo de severidad son negativas como se aprecia en todos los paneles de la figura. Las series de SPI y de SRI, figs. 4.12a) y d), tienen una marcha similar de severidad, esta similitud también se verifica en los análisis previos de frecuencia (figs. 4.4 y 4.5) y duración (figs. 4.7-4.9) de sequías. En general el comportamiento de SRI tiene menos variabilidad que SPI, pero ambos indicadores parecen detectar características similares de los eventos secos. También se aprecia en la figura 4.12b) que el indicador de evapotranspiración es el que muestra mayor variabilidad de los indicadores analizados, inclusive más que SPI. Esta condición más fluctuante

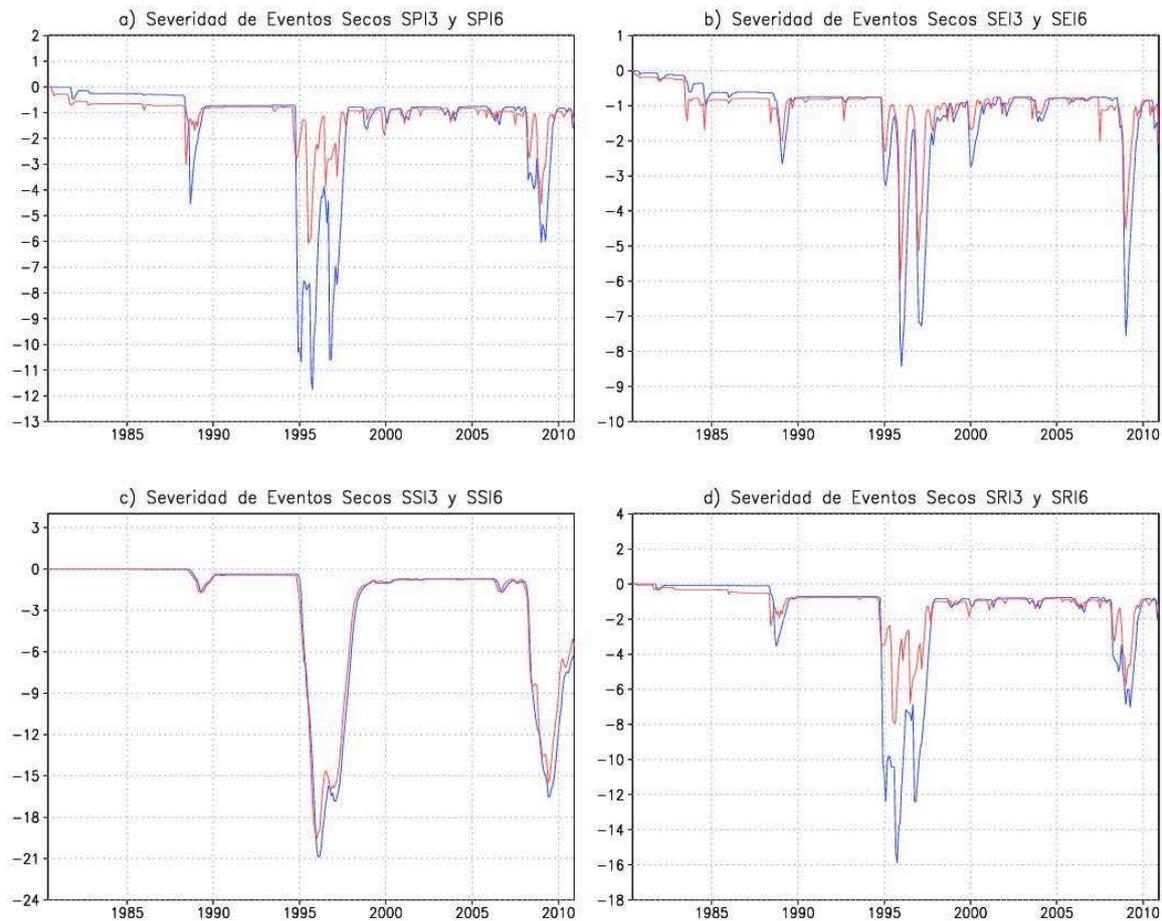


Figura 4.12: Severidad de sequías detectadas en zona 2, según indicadores de escala de tiempo 3 meses en rojo y 6 meses en azul: a)SPI3/6, b)SEI3/6, c)SSI3/6 y d) SRI3/6.

en el tiempo permite establecer que la evapotranspiración sea la variable de mayor sensibilidad de las 4 estudiadas; este rasgo es particularmente útil en la detección del inicio de posibles eventos extremos. La menor variabilidad temporal es una particularidad del indicador SSI, como se aprecia en figura 4.12c), esto hace que el índice presente series de severidad casi iguales en ambas escalas temporales; algo similar ocurre en la figura 4.5c) de frecuencias acumuladas de sequías del mismo indicador. Una característica común detectada en todos los indicadores es que, en los eventos más severos detectados la magnitud de la severidad aumenta con la escala de tiempo del índice con que se la evalúa. De esta forma la severidad determinada con índices de 6 meses de escala temporal (líneas azules) es mayor en magnitud que la estimada con índices de 3 meses (líneas rojas), probablemente debido a una menor variación más sostenida en el tiempo y mayor duración.

El evento seco detectado de mayor severidad lo constituye la sequía que comenzó a fin de 1994, según los índices SEI y SPI, y que se prolongó hasta 1997 según SSI y SRI. Los valores de severidad del evento seco varían de acuerdo al indicador considerado en su estimación. La máxima severidad detectada corresponde a SSI y es casi 3 veces mayor que la máxima correspondiente a SEI. Todos los indicadores coinciden en detectar que la máxima severidad se produjo hacia fin de 1995/comienzo de 1996. Este evento ha sido destacado por varios

estudios (por ejemplo Barrucand et al., 2007; Minetti et al., 2007; Penalba y Llano 2008) como un evento particularmente seco en esta región. El análisis a través de múltiples variables puede ayudar a identificar diferencias dentro de un mismo evento. En este sentido si se analiza el evento solo a través de SSI se puede ver un solo episodio seco muy severo, pero cuando se agregan otros indicadores el análisis puede variar. Al incluir SPI, SRI y SEI el análisis cambia, se ve que el episodio seco tuvo una recuperación, y que pueden haber sido dos eventos secos separados por corto tiempo donde hubo una recuperación (de acuerdo a SPI6), o incluso tres eventos secos (según SEI3/6, y SPI3); el indicador SRI tiene un comportamiento muy parecido a SPI. Esto revela la importancia de analizar los eventos extremos a través de diferentes perspectivas mediante variables que se caractericen por tener diferentes respuestas ante una misma perturbación.

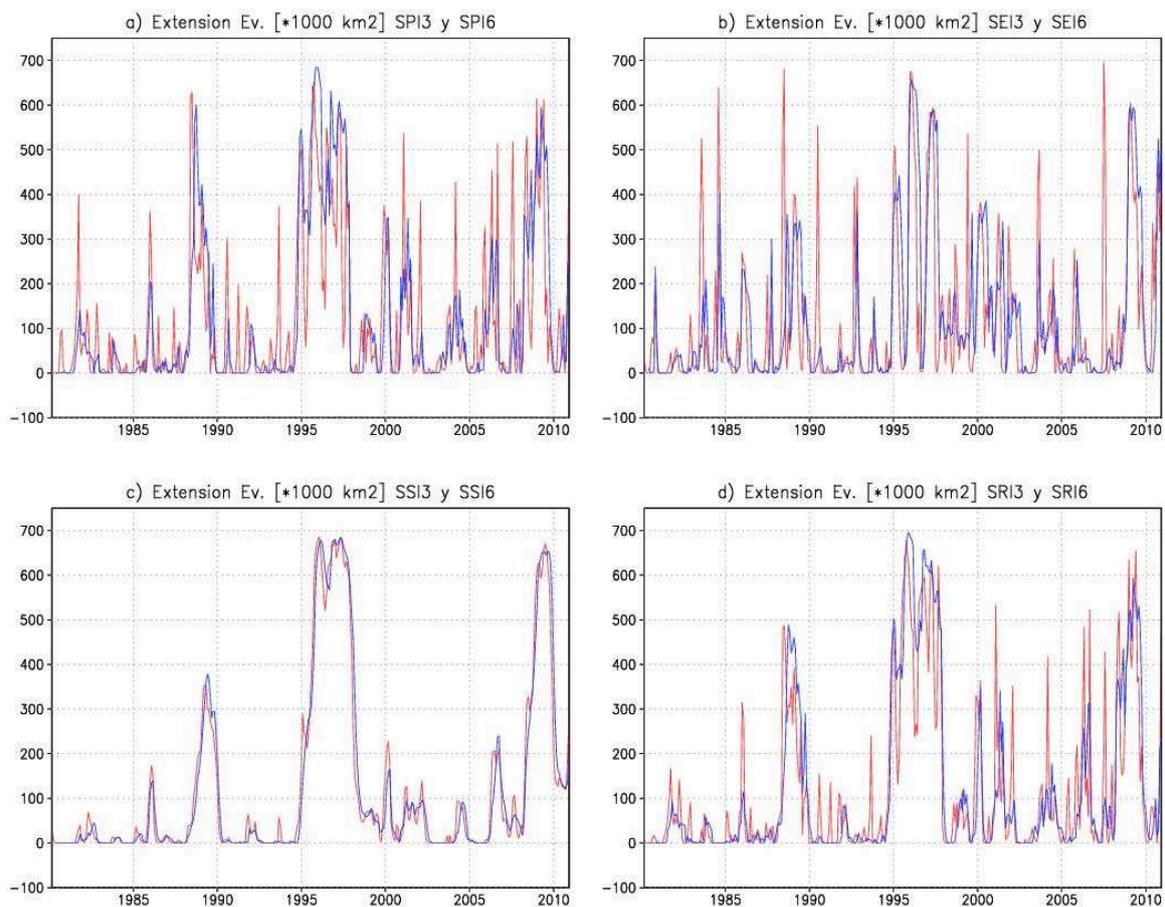


Figura 4.13: Extensión areal de sequías en zona 2, expresadas en $[km^2] \times [1000]$ según indicadores con escala de tiempo 3 meses en rojo y 6 meses en azul: a)SPI3/6, b)SEI3/6, c)SSI3/6 y d) SRI3/6.

Otro evento seco severo es el detectado durante 2008 y que se extendió hasta 2009, que fue en su momento el evento más intenso de los últimos 50 años de registro (Skansi et al., 2009; Müller et al., 2014). Sobre este evento D'Ambrosio et al. (2013) destacan una marcada disminución de la precipitación hacia el sur de la Región Pampeana en 2008, y una reducción semejante en 2009 pero hacia la zona norte de ésta, concentrándose la precipitación en las estaciones de primavera y otoño principalmente. Esta distribución particular de la precipitación en toda la región, ocasionó

una baja en los rendimientos de trigo de alrededor del 50% y una mortalidad de 1,5 millones de bovinos en Argentina (Sheffield y Wood, 2012), y causó pérdidas económicas importantes en toda la región de zona 2 (Bidegain, 2009). Los valores de las series de severidad no muestran al evento seco registrado en 1988/89 como uno particularmente severo, y solo se encuentra en tercer lugar entre los más severos según los paneles 4.12a), c) y d); la alta variabilidad temporal de SEI hace que existan otros eventos con severidad similar. No obstante debido a los impactos que produjo esta sequía ha sido destacada como una de las más severas del SESA en las últimas décadas (ver por ej., Vargas et al. 2010). En esta región de estudio la ocurrencia de eventos secos y húmedos está fuertemente relacionada al fenómeno del ENSO (El Niño-Southern Oscillation), El Niño con las anomalías positivas y lluvias superior al valor normal y La Niña relacionándose con sequías (por ej., Grimm et al., 2000; Paegle y Mo, 2002; Garreaud et al., 2009). Los resultados de este trabajo permiten mostrar que las sequías más importantes ocurrieron durante eventos La Niña en los años 1988/89, 1995/96 y 2008/9, ratificando la influencia de este fenómeno en la ocurrencia de los eventos extremos en esta zona. Más aún, existen estudios realizados sobre la implicancia del fenómeno del ENSO en la modulación de los eventos secos a futuro, y Dai (2011) ha establecido que durante el siglo XXI las variaciones del ENSO pueden reducir la duración de las sequías, en los próximos 20-50 años; esta característica también se destacó en Penalba y Rivera (2013 y 2016a).

La extensión areal de los eventos secos moderados a extremos ocurridos en zona 2 durante el período 1980-2010, expresados en $[km^2]$ se muestra en la figura 4.13. Las series de tiempo de los indicadores con escalas temporales de 3 meses en rojo y 6 meses en azul permiten indicar, con excepción de SSI con un tiempo de respuesta mayor a las entradas del sistema, que las sequías detectadas con los indicadores de 3 meses son más extensas que las observadas con los índices de 6 meses. El análisis conjunto con la figura 4.12 de severidad de sequías permite establecer que los indicadores con mayor escala temporal (6 meses) permiten determinar eventos extremos con severidades mayores que los eventos detectados con escalas temporales menores, y que además en general son menos extensos arealmente que los hallados con índices de 3 meses. Existe una coincidencia en mostrar que los eventos secos de mayor severidad, registrados en 1995-97 y 2008/9, se extendieron por más de 600.000 $[km^2]$ en la región, en particular el primero de estos llegando a casi 700.000 $[km^2]$ de acuerdo a los 4 indicadores y en las 2 escalas temporales evaluadas. Estas sequías fueron importantes no solo desde el punto de vista de la severidad sino también por su extensión areal, potenciando los impactos negativos en la región que se traducen en pérdidas económicas. El evento de 1988/89 alcanzó los 600.000 $[km^2]$ según SPI3 y SPI6, pero para SRI y SSI apenas superó los 400.000 $[km^2]$ y 500.000 $[km^2]$ respectivamente; mientras que para SEI3 llegó a casi 700.000 $[km^2]$ para SEI6 solo alcanzó la mitad.

El grado de vinculación entre severidad y extensión areal en zona 2 se presenta en la figura 4.14 para los índices SPI y SEI de 3 y 6 meses, mientras que el mismo análisis para SSI y SRI se muestra en la figura 4.15. Todos los diagramas muestran dispersiones de puntos con pendiente negativas debido a los valores negativos de severidad. Se estimaron valores del

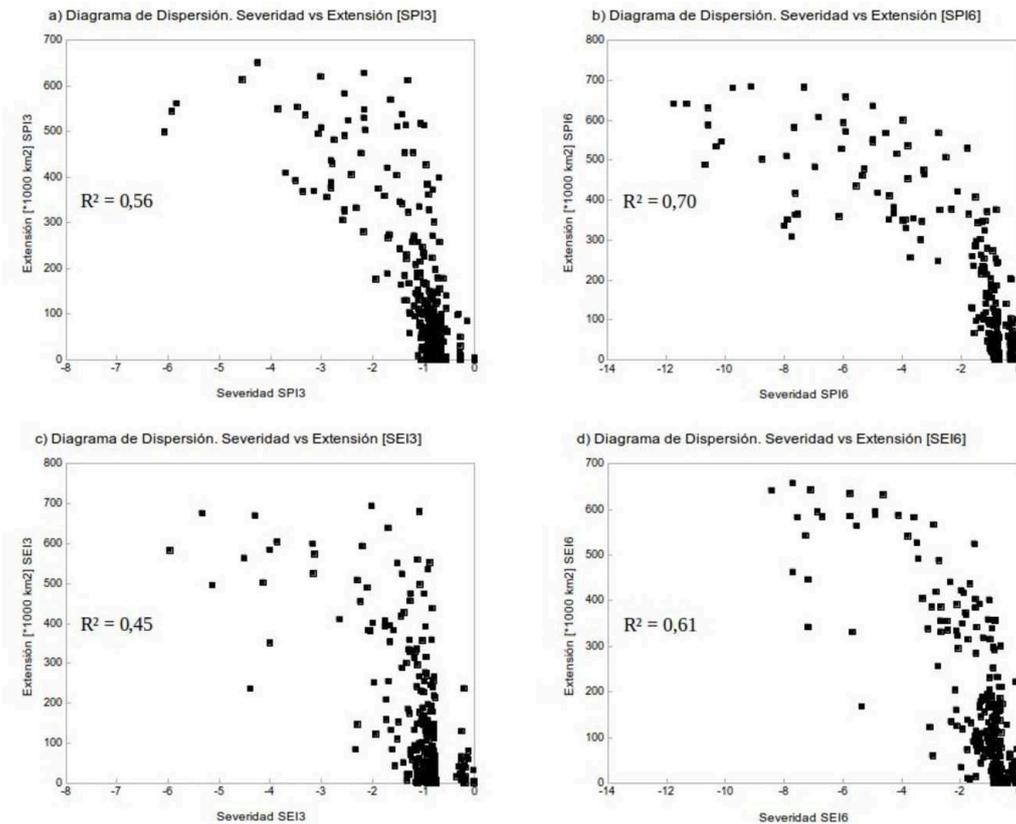


Figura 4.14: Diagramas de dispersión entre severidad y extensión areal de sequías según índices: a) SPI3, b) SPI6, c) SEI3 y d) SEI6.

coeficiente de determinación R^2 es decir el cuadrado del coeficiente de correlación en cada uno de los diagramas. La mejor vinculación entre sequías extensas y severas se produce para los indicadores de SSI3 y SSI6, ambos con $R^2 = 0,85$. Por otro lado la vinculación más pobre se produce para los indicadores de mayor fluctuación temporal, los coeficientes más bajos con $R^2 = 0,45$ y $R^2 = 0,61$ se han obtenido para SEI3 y SEI6 respectivamente. El resto de los indicadores presentan R^2 entre 0,6 y 0,7. Este análisis infiere que los indicadores de menor variabilidad presentan una mejor correlación entre severidad y extensión areal, lo que indica que cuando un evento seco es extenso existe una posibilidad elevada que también sea severo; por el lado contrario cuando el indicador posee una variabilidad temporal mayor, las sequías pueden ser extensas, como se aprecia en las figuras 4.13a) y b), pero esta condición por sí sola no es suficiente para afirmar que las mismas sean severas.

4.3.4. Análisis de Cultivos.

La visualización del rendimiento de los cultivos muestra una señal de cómo un evento de sequía podría impactar en la producción de cereales en la región. Dado que estos indicadores proveen información sobre el rendimiento de producción por hectárea, luego una disminución en el rendimiento ocasionada por una disminución de la disponibilidad de agua puede implicar pérdidas económicas directas. Las disminuciones en el rendimiento de cultivos se encuentra

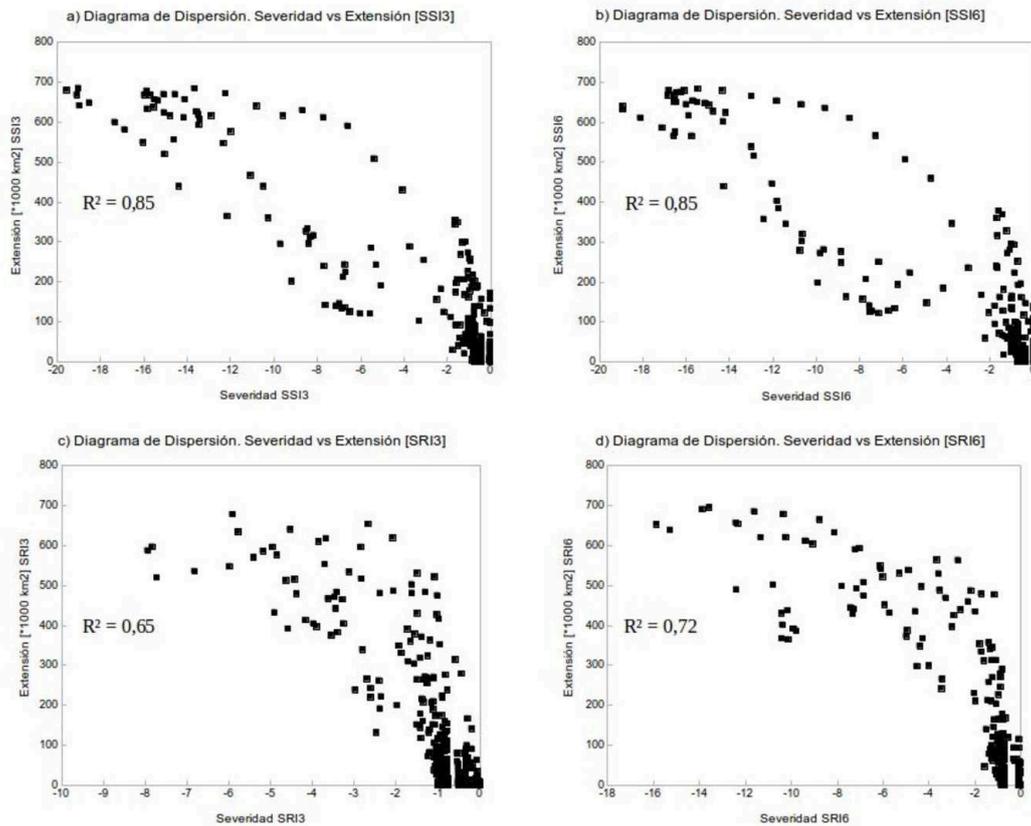


Figura 4.15: Ídem figura 4.14 para índices: a) SSI3, b) SSI6, c) SRI3 y d) SRI6.

relacionada con eventos secos, ya que el riego en esta región representa menos del 3% de la región (Siebert et al., 2013). Además, a través de las marchas de los rendimientos entre cultivos, permite identificar cuáles de estos cultivos son más afectados por los eventos secos. Las series temporales de rendimiento de cultivos de trigo, maíz y soja de las provincias de Santa Fe y Córdoba corresponden a campañas entre 1969 y 2016, y se observan en la figura 4.16a), c) y e) respectivamente. Los datos refieren a valores de rendimientos anuales para cada cultivo expresados en $[\text{kg } \text{ha}^{-1}]$ y fueron obtenidos del Ministerio de Agricultura, Ganadería y Pesca de Argentina (datos disponibles <https://datos.magyp.gob.ar/reportes.php?reporte=Estimaciones>). Estas series muestran en ambas provincias una tendencia de aumentos de rendimiento durante todo el período de datos en todos los cultivos estudiados. Los incrementos varían de 1.500 $[\text{kg } \text{ha}^{-1}]$ a casi 4.000 $[\text{kg } \text{ha}^{-1}]$ en trigo y soja, figura 4.16a) y e); mientras que los valores son aún mayores para el maíz, que oscila entre 3.000 $[\text{kg } \text{ha}^{-1}]$ en 1969 y casi 10.000 $[\text{kg } \text{ha}^{-1}]$ en 2009 figura 4.16c).

En las series de tiempo de los 3 cultivos se observan tendencias positivas en los rendimientos, con un comportamiento temporal con distintos grados de crecimientos para cada cultivo. La tendencia del trigo muestra un cambio positivo significativo desde mediados de 1990, mientras que el mayor cambio en la tendencia de los rendimientos de soja y maíz se produce a comienzos de los años 1990 y a fines de los años de 1980, respectivamente. Una causa de los cambios en las tendencias radica en la aplicación de tecnologías agrícolas mejoradas, como por ejemplo las prácticas de fertilización y el mejoramiento genético de los cultivos. Particularmente, la

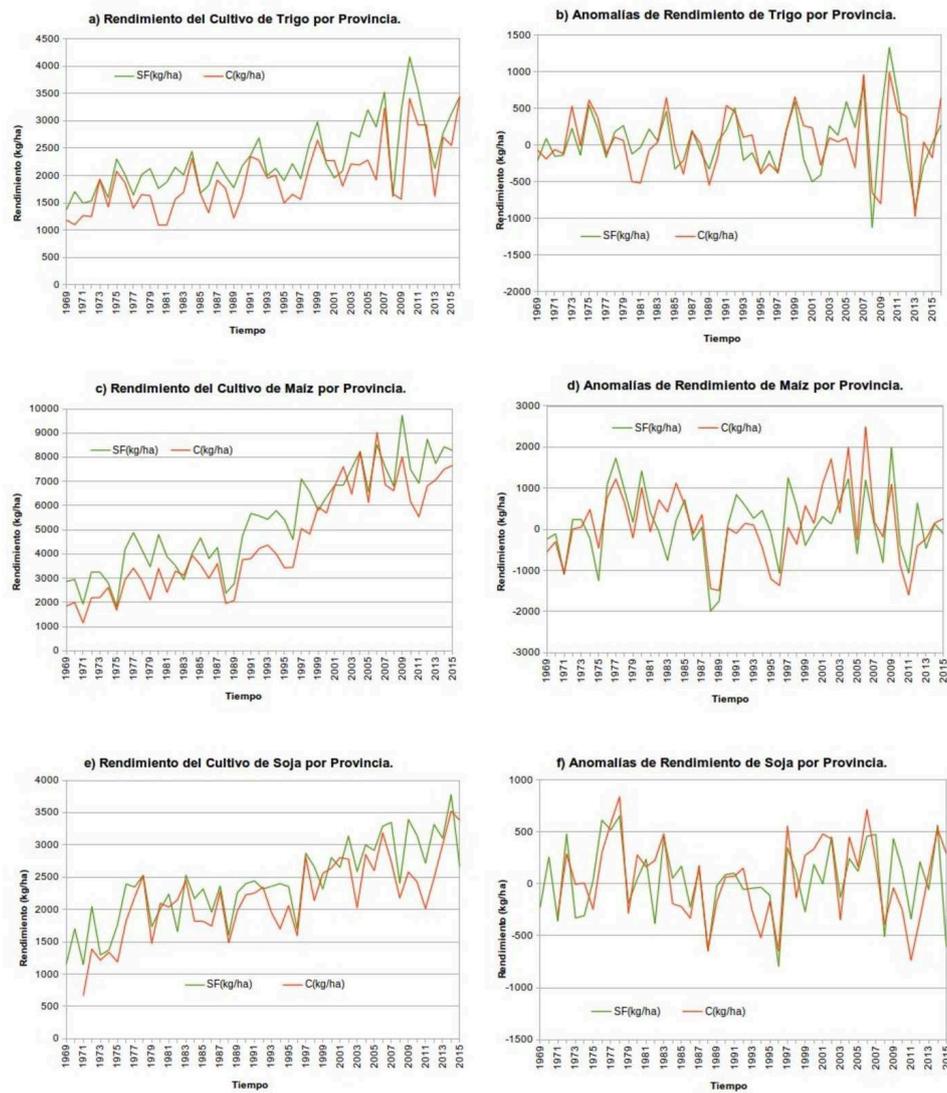


Figura 4.16: Valores de rendimiento de a) maíz, c) trigo y e) soja; y anomalías de rendimiento de b) maíz, d) trigo y f) soja, expresadas en $[\text{kg ha}^{-1}]$, para las provincias de Santa Fe (verde), Córdoba (rojo). 1969-2016.

agricultura argentina se vio beneficiada por la estabilidad económica en la década del noventa, favoreciendo un mayor uso de fertilizantes, agroquímicos y el manejo de cultivos genéticamente modificados (Bert et al., 2006). El desarrollo de estas tecnologías de cultivo podría haber mejorado las prácticas agrícolas, lo que resultó en aumentos de los rendimientos de los cultivos en la región de cultivos básicos (Minetti et al., 2007).

Las tendencias de crecimiento no impiden ver que existen disminuciones en los rendimientos que resultan ser importantes en cada uno de los tres cultivos y en ambas provincias, por ejemplo en los años 1988/89, 1995/96 y 2008/9. Con el fin de detectar anomalías crecientes y decrecientes y aislar los rendimientos netos de las mejoras tecnológicas; se filtraron los rendimientos de los cultivos extrayendo la tendencia de cada serie de las dos provincias mediante el ajuste una tendencia polinómica cúbica a cada serie temporal. El resultado de esta práctica se aprecia en las figura 4.16b), d), y f) donde se muestran las series de las anomalías de rendimientos, o

series filtradas sin tendencia. Las anomalías del maíz, figura 4.16d), parecen indicar una mayor amplitud respecto del valor medio que las series de los cultivos de trigo y soja, figura 4.16b) y f). Los valores de apartamiento respecto al valor medio de las anomalías del maíz suelen exceder los $1.000 \text{ [kg ha}^{-1}\text{]}$ de déficit en años cuando ocurren eventos extremos secos, mientras que para el trigo y la soja las anomalías negativas parecen encontrarse más cerca de su valor medio y llegando eventualmente por debajo de los $500 \text{ [kg ha}^{-1}\text{]}$.

Los valores mínimos obtenidos de las series filtradas de soja y maíz se registraron en años con sequías severas como 1988/1989 y 1995/1996, ver también figura 4.12; Un comportamiento similar, aunque no tan claro, se produce en las series de trigo. Los eventos secos registrados en 1988/89, 1995/96 y 2008/9 fueron los mayores contribuyentes a la disminución del rendimiento en al menos uno de los tres cultivos. Los valores de rendimiento más bajos se registraron en 1988 y 1989 para el maíz, en 1996 para la soja (pero también tuvieron pérdidas significativas durante 1988 y 2008) y finalmente en 2008 para el trigo. Este comportamiento de los cultivos refuerza los resultados reportados en la figura 4.12, que señalan a estas sequías como las más severas identificadas en la región, y coinciden en mostrar también lo que se estableció en Leva et al. (2012) donde se indicó que en las últimas décadas las sequías en la región del norte santafesino, excepto en los años 1998 y 2003, aumentaron su duración e intensidad, destacando que en 2009 particularmente la sequía fue extrema (Corti y Mendoza Gallo, 2012). Resulta importante señalar el impacto negativo en el cultivo de maíz producido en la sequía 1988/1989, cuando la pérdida de rendimiento alcanzó cerca de $2.000 \text{ [kg ha}^{-1}\text{]}$ en 1988 y más de $2.000 \text{ [kg ha}^{-1}\text{]}$ en 1989 en provincia de Santa fe; en Córdoba la pérdida fue algo más leve (ver la figura 4.16d)).

En concordancia con estos resultados, varios estudios mencionan a la sequía de 1988/89 como una de las secuencias secas más largas en la zona de la Llanura Pampeana y que causó grandes pérdidas económicas debidas al déficit hídrico acumulado, particularmente en la región sur de Santa Fe y el norte de Buenos Aires (por ejemplo Naumann et al., 2008; Penalba y Llano 2008; y Vargas et al., 2010). No obstante esta sequía no fue particularmente severa (ver figura 4.12); solo se muestra una serie de severidad moderada de acuerdo a SPI/SRI y baja según el resto de los indicadores. Tampoco fue un evento extenso (ver figura 4.13), solo SPI3/6 y SEI3 indican una extensión mayor de 600.000 km^2 . La ausencia de la sequía 1988/89 particularmente en la serie de severidad aunque también en la serie de extensión areal, probablemente sea debido a que la zona 2 constituye un área bastante mayor que la de las provincias de Santa Fe y Córdoba. En consecuencia esta sequía no muestra impactos tan evidentes como otros eventos ocurridos; este evento muestra consecuencias en la serie de rendimientos de soja (figura 4.16f)) con anomalías negativas de menos de $500 \text{ [kg ha}^{-1}\text{]}$ en 1988. Sin embargo, en este cultivo el descenso máximo ocurrió en 1996 cercano a $1.000 \text{ [kg ha}^{-1}\text{]}$ de disminución. Por otro lado, la sequía de 2008 causó las mayores pérdidas en la producción de trigo, con anomalías negativas menores a $1.000 \text{ [kg ha}^{-1}\text{]}$ como se ve en figura 4.16b).

Considerando las series de tiempo de severidad de cada indicador de 3 meses en zona 2, series de

	Trigo (SF)	Maíz (SF)	Soja (SF)	Trigo (Có)	Maíz (Có)	Soja (Có)
SPI3	0,52	0,46	0,59	0,49	0,69	0,60
SEI3	0,43	0,37	0,47	0,41	0,64	0,51
SSI3	0,37	0,26	0,49	0,56	0,60	0,50
SRI3	0,51	0,42	0,62	0,71	0,75	0,77

Cuadro 4.3: Coeficientes de determinación R^2 entre Severidad y Anomalías de rendimiento de cultivos de las provincias de Santa Fe (SF) y Córdoba (Có), utilizando indicadores de escala temporal de 3 meses.

líneas rojas en figura 4.12, y las series filtradas de rendimientos de cultivos para cada provincia, figuras 4.16b), d) y f), se estimaron valores de coeficientes de determinación R^2 esta variable y las anomalías de rendimientos de provincias de Santa Fe y Córdoba; con el objeto de determinar el grado de vinculación que existente. Para la estimación de los coeficientes se igualaron las series temporales a un mismo número de años de datos, y esto se logró promediando los valores de severidad a fin de lograr tantos datos de esta variable como datos de rendimientos; el período de análisis es de 1981 hasta 2010 y en tabla 4.3 se muestran los valores obtenidos. Estos coeficientes estimados, aunque bajos en algunos casos, permiten establecer cosas interesantes. En primer lugar los valores de coeficiente de determinación más promisorios se obtuvieron para el cultivo de maíz en la provincia de Córdoba y es consistente con todos los indicadores evaluados destacándose el valor de $R^2 = 0,75$ obtenido del índice SRI3. Asimismo los valores del cultivo de soja no son despreciables en Córdoba, donde además el trigo posee los coeficientes más bajos. En Santa Fe los coeficientes más altos se obtienen para el cultivo de soja, por sobre los de maíz y trigo con $R^2 = 0,62$ obtenido también de SRI3; a nivel general para la provincia de Santa Fe los valores resultan siempre más bajos que los obtenidos para Córdoba. De estos valores se destaca que las sequías moderadas a extremas más severas producen menores rendimientos en los cultivos de maíz en la provincia de Córdoba, mientras que esas sequías severas en Santa Fe implican una mayor pérdida en el rendimiento de soja. Asimismo el indicador que mejor representa esta vinculación es SRI3 en Córdoba, y en menor medida en Santa Fe donde se equipara con SPI3.

4.4. Conclusión.

Se han caracterizado como eventos secos a todos aquellos que son menores o iguales al umbral -1σ , esto permitió determinar características de las sequías moderadas a extremas en la zona 2. Esta región en particular constituye una zona donde la producción de trigo, maíz y soja se encuentra entre la más intensa de todo el país. El análisis ha consistido en examinar las características físicas de los eventos extremos secos, como frecuencia, duración, severidad y extensión areal; mediante el uso de indicadores estandarizados construidos en base a las variables simuladas más sensibles a las sequías como SPI, SEI, SSI y SRI, para las escalas de tiempos

de 3 y 6 meses. También se estudió el impacto de las sequías sobre el rendimiento de cultivos de mayor producción. La consideración del comportamiento de varios de estos indicadores en forma simultánea resulta útil para la planificación y el manejo de los impactos, que la ocurrencia de eventos extremos secos pueda ocasionar en una región. Según la variabilidad temporal de los índices, existen algunos de respuesta más lenta como SSI mientras que SPI, SRI y SEI responden más rápidamente ante una variación en la disponibilidad de agua. Entre ellos, SEI es el que presenta mayor sensibilidad por su mayor variabilidad. Esto permite que rápidamente pase de una situación de déficit a una de exceso, y lo convierte en el más apropiado para detectar los posibles comienzos de los eventos extremos secos. De manera opuesta SSI es el que menor variación temporal presenta y es el que mejor determina la persistencia del evento.

La distribución espacial de la frecuencia de ocurrencia de sequías destacó una mayor probabilidad a que se produzcan sequías en la parte norte de zona 2 con un valor de 0,19, mientras que hacia el sur la probabilidad se reduce. Las frecuencias acumuladas de sequías mostraron variaciones importantes de frecuencia durante años 1988/89, 1995/96 y 2008/9 en todos los indicadores analizados. El análisis de duración en esta zona permitió establecer que los eventos secos más frecuentes son de corta duración, hasta 3 meses; y que la frecuencia disminuye a medida que la duración aumenta. Los valores de frecuencias de los indicadores de 6 meses muestran menor cantidad de eventos de corta duración que los de 3 meses; pero en forma opuesta permiten detectar con mayor frecuencia sequías de mayor duración. Se estudió si existe alguna región que manifieste mayor frecuencia de sequías con duraciones 1 mes y 2 meses, y se encontró que la región limítrofe entre Argentina Brasil y Uruguay presenta las frecuencia más altas, así como también la zona sur de la cuenca del Plata.

Las series de tiempo de extensión areal de indicadores con escalas de tiempo de 3 y de 6 meses indican que, con excepción de SSI que tiene un mayor retardo en las respuesta a las entradas del sistema, el resto coinciden en destacar que indicadores de 3 meses detectan sequías que son más extensas que las estimadas a través de indicadores de 6 meses. Esta cualidad, en conjunto con el análisis de severidad permite afirmar que los indicadores de mayor escala temporal determinan eventos extremos con severidades mayores en magnitud que los mismos eventos con escalas temporales menores, y que resultan menos extensos arealmente que los de escalas temporales de 3 meses. La correlación existente entre las series de severidad y las de extensión areal determinó que los indicadores de menor variabilidad tienen mejor ajuste entre severidad y extensión areal, esto indica que cuando un evento seco es extenso existe alta posibilidad que sea severo cuando es detectado a través de SSI. Por otro lado cuando el indicador posee una variabilidad temporal mayor, como SEI, las sequías pueden ser extensas, pero esta condición no es suficiente para afirmar que las mismas sean severas.

Los rendimientos de cultivos muestra impactos de las sequías en la producción de los mismos y proporcionan una idea acerca de las pérdidas económicas en términos de una caída en el rendimiento. Se filtraron las series de rendimiento y se obtuvieron series de anomalías que muestran que el rendimientos del cultivo de maíz posee mayor variación respecto al valor medio,

mientras que tanto el trigo como la soja presentan una variación menor. Los eventos secos registrados durante 1988/89, 1995/96 y 2008/9 fueron los que contribuyeron a la disminución del rendimiento en al menos uno de los tres cultivos, se registraron en 1988 y 1989 para el maíz, en 1996 para la soja (pero también tuvieron pérdidas significativas durante 1988 y 2008) y en 2008 para el trigo. El coeficiente de determinación R^2 entre series filtradas de los cultivos de Córdoba y Santa Fe y series de severidad para indicadores de 3 meses, determinó que las sequías más severas producen menores rendimientos en los cultivos de maíz en la provincia de Córdoba, mientras que esas sequías en Santa Fe implican una mayor pérdida en el rendimiento de soja.

Capítulo 5

Sistema de Pronóstico y Monitoreo de Eventos Extremos.

Durante el comienzo de esta disertación se destacaron los beneficios de poder contar con un sistema de monitoreo de eventos secos y además poder realizar pronósticos de las variables hidrológicas de superficie sensibles a las sequías. Que posteriormente mediante indicadores construidos sobre estas mismas se pueda analizar las sequías que ocurren en esta región de la cuenca del Plata establecida como zona 2. Previamente en este trabajo se han utilizado datos 6-horarios de reanálisis CFSR (Saha et al., 2010) para caracterizar sequías a través del desarrollo de una climatología basada en este tipo de eventos. El reanálisis mencionado llega hasta completar el año 2010, a partir de allí se comenzó a usar como forzantes del modelo hidrológico, datos de pronósticos a tiempo casi real (TCR) de la versión 2 del *Climate Forecast System* (CFSv2, por su sigla en inglés) desarrollado por Saha et al. (2014), con el mismo paso de tiempo que el reanálisis.

La disponibilidad de datos del modelo de pronóstico global casi a tiempo real, permite realizar simulaciones de las condiciones de superficie hasta la actualidad. En la figura 5.1 se muestra la estructura del sistema de simulaciones utilizadas tanto para generar la climatología de sequías como para realizar el monitoreo. La inicialización de la simulación con la condición actual, datos de CFSv2, se realizó utilizando el estado del sistema generado por la simulación previa, es decir con los datos del CFSR durante 1980-2010. La versión 2 de pronósticos fue desarrollada continuando con las mejoras impuestas en el reanálisis del CFS (Saha et al., 2010). El CFSR generó estados iniciales avanzados que caracterizan al sistema acoplado de atmósfera, océano, hielo y tierra, para este nuevo sistema de pronósticos; a su vez CFSv2 ha tenido mejoras y utiliza una actualización del modelo de superficie de 4 niveles, un sistema iterativo de 3 niveles en la capa de hielo, y mejoras sustanciales en el sistema de asimilación de datos (Saha et al., 2014). Por otro lado CFSv2 también genera pronósticos estacionales de larga duración hasta 9 meses, esos datos son utilizados posteriormente en este capítulo como forzantes del modelo de superficie para generar condiciones de pronóstico de eventos secos.

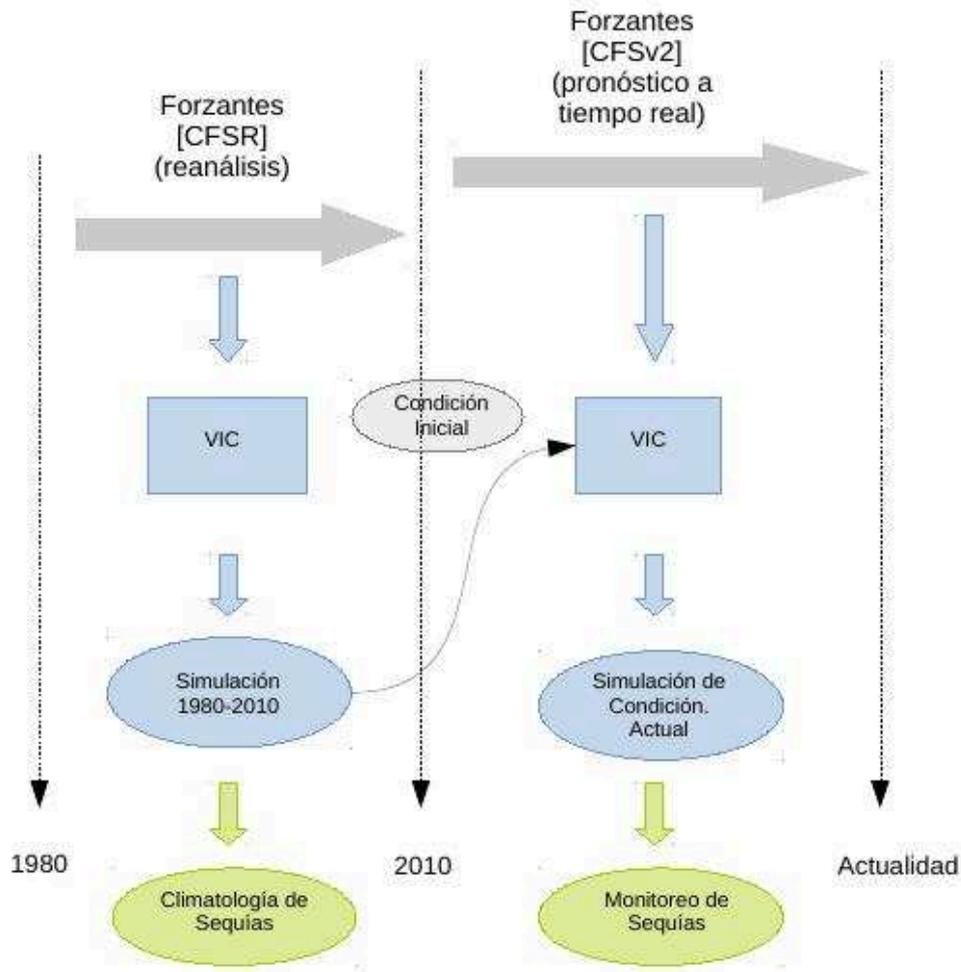


Figura 5.1: Esquema de funcionamiento del sistema de monitoreo, a través del uso de forzantes a tiempo casi real.

5.1. Monitoreo de Eventos Extremos Secos.

Con los datos a tiempo casi real como forzantes, se construyeron series temporales de los indicadores con escalas de tiempo de 3, 6 y 9 meses utilizando la misma metodología desarrollada anteriormente (ver sección 2.2 y figura 2.7), para variables simuladas de evapotranspiración, humedad del suelo, escorrentía y también precipitación, como se aprecia en la figura 5.2b)-e). La figura 5.2a) presenta la serie de precipitación a la que se le extrajo el ciclo medio anual del período completo de análisis generando las anomalías.

La precipitación es parte de los forzantes del modelo de superficie, por lo tanto los datos de esta variable no son modelados sino que son datos crudos del CFS y re-grillados a la resolución de trabajo. Los valores de precipitación presentan anomalías positivas de más de 60 [mm], uno en 2007 llegando a 100 [mm] y otro hacia finales de 2012 de casi 80 [mm]. Entre ambos máximos se encuentra un período dominado prácticamente por anomalías negativas y donde además se detectaron 2 eventos secos, el de mayor magnitud durante 2008/9 y otro menos importante en 2011/12. En ambos casos coincidieron con eventos ENSO Niña moderados

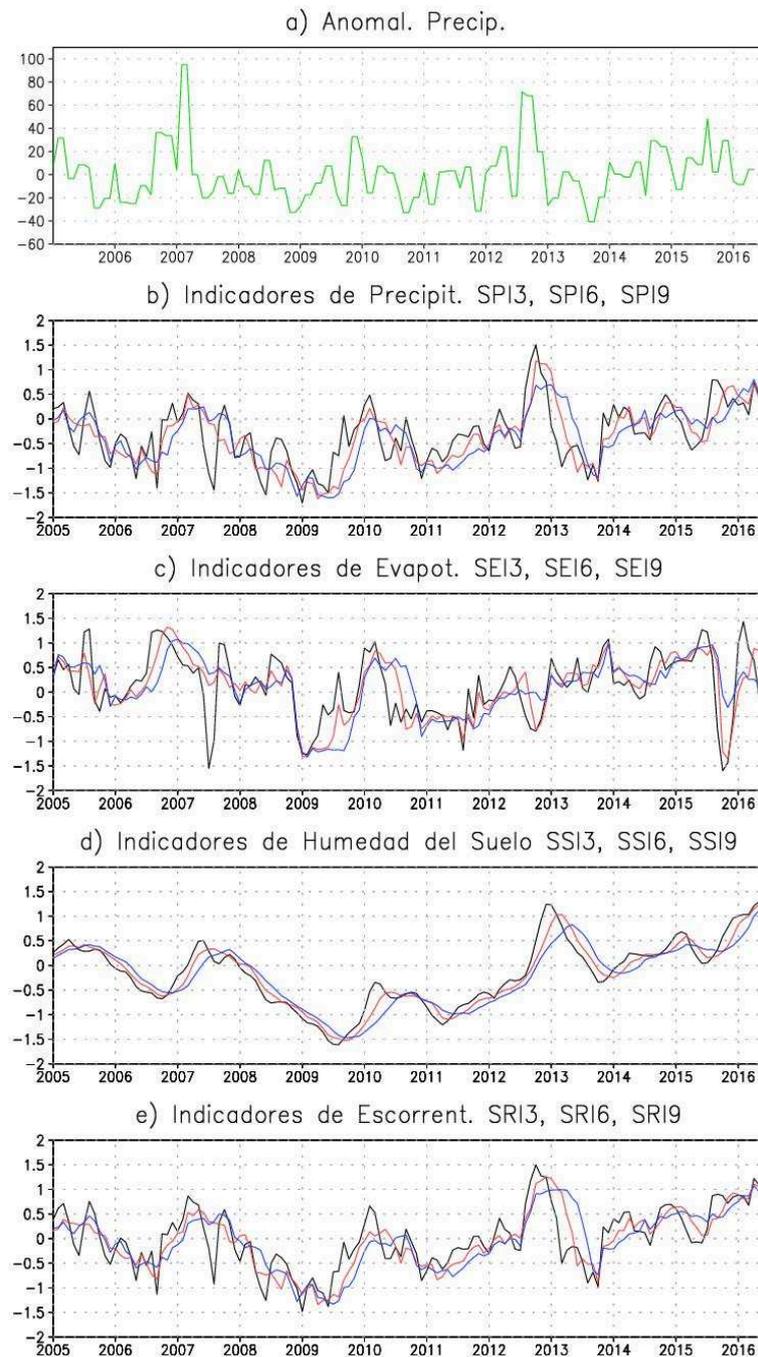


Figura 5.2: Series de tiempo del período ENE 2005 a JUN 2016 en zona 2: a) Anomalías de Precipitación en [mm]. Indicadores Estandarizados: b) SPI3 (negro), SPI6 (rojo) y SPI9 (azul); c), d) y e) ídem b) para SEI, SSI y SRI respectivamente.

en los años previos, durante 2007/8 y 2010/11 respectivamente. A pesar de que ambos eventos Niña tuvieron magnitudes de moderadas a extremas, respecto del cuantificador Oceanic Niño Index (ONI por sus siglas en inglés), ninguno llegó verdaderamente a un valor extremo del indicador y las dos se prolongaron durante un período de tiempo similar (ver por ej. <http://ggweather.com/enso/oni.htm>).

La observación del primer evento seco se puede visualizar en la marcha de los indicadores SPI, SEI y SRI de menor escala temporal (en líneas negras) en figura 5.2b), c) y e), en los cuales existe un descenso de los mismos a mediados de 2007 que llegan a valores del indicador de -1,5. Mientras que la menor variabilidad temporal del indicador SSI hace que esta sequía recién sea detectada hacia la mitad del año 2008, como se puede ver en la figura 5.2d). La sequía siguiente fue de menor intensidad y esto también se manifiesta en las series de los indicadores SPI3, SRI3 y SEI3 donde los mismos no muestran con tanta claridad su inicio, como ocurrió durante mediados de 2007 para la sequía previa. En cambio sí muestran que tanto SPI3 como SRI3 tienen un valor de -1 hacia el final de 2010, mientras que SEI3 presenta un período desde mediados de 2010 hasta mitad de 2011 acumulando déficit a un valor prácticamente constante de -0,5. Entre ambas sequías, hacia finales de 2009 y principios de 2010, las series de SPI, SEI, y SRI tienen valores positivos, esta recuperación indica que la primer sequía había finalizado; a diferencia de SSI que nunca logró recuperarse desde inicio de 2008. Es decir que para este indicador solo ha existido un solo evento seco que comenzó durante 2008 y se prolongó hasta mediados de 2012 aproximadamente de acuerdo con las series de la figura 5.2d). Las series de los indicadores de 6 y de 9 meses, en colores rojo y azul respectivamente, tienen marchas un tanto más suavizadas que los de 3 meses, pero aún en ellos también se nota una brusca caída hacia fines de 2008 en particular para SEI6 y SEI9 por debajo de -1. Esta menor variabilidad asociada con el incremento de la escala temporal del índice hace más difícil poder determinar con certeza el inicio de las sequías.

La figura 5.3 muestra series temporales de severidad para indicadores de 3 y 6 meses, estimadas de igual forma en que se definió en capítulo 4 que corresponden a la zona 2. En dicha figura los diferentes indicadores y sus escalas de tiempo, destacan que existen tres comportamientos bien marcados en la definición de las sequías. Por un lado se encuentran las series de SPI y SRI que presentan dos sequías diferenciadas, la primera de ellas de mayor severidad, al comienzo de 2008 que se prolonga hasta mediados de 2009, durante esta sequía los índices de 3 meses muestran recuperación a fines de 2008; y la segunda sequía menos severa desde fin de 2010 hasta mediados de 2011, figuras 5.3a) y c). Un segundo comportamiento que presenta una sola sequía prolongada que comienza en 2008 y llega hasta mediados de 2012, según los indicadores SSI3 y SSI6. Por último los indicadores SEI detectan las dos sequías, pero la duración de cada una es menor que la presentada por los demás índices. Esto indica que la mayor variabilidad temporal de SEI evidencia una recuperación en el indicador, lo que puede llevar a conclusiones erróneas si no se analiza en conjunto con las otras variables.

Los impactos producidos por las sequías mencionadas se pueden ver en la figura 4.16 del capítulo

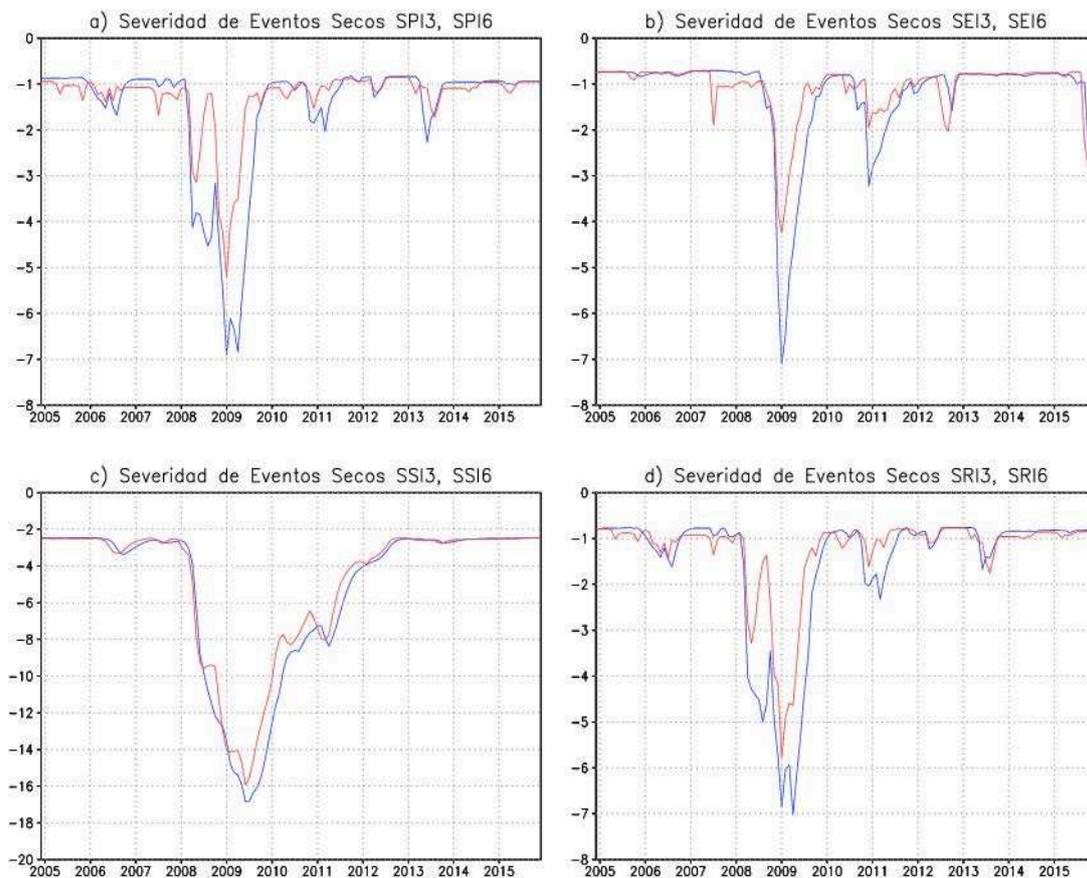


Figura 5.3: Series de tiempo de Severidad de Sequías del período ENE 2005 a JUN 2016 en zona 2 correspondiente a: a) SPI3 (rojo) y SPI6 (azul), b), c) y d), ídem a) para SEI, SSI y SRI, respectivamente.

4, en dicha figura se muestran series de rendimientos filtradas de cultivos de trigo, maíz y soja para provincia de Santa Fe y Córdoba. El rendimiento del trigo, figura 4.16b), presenta anomalías negativas de $1000 \text{ [kg ha}^{-1}\text{]}$ para ambas provincias en los años 2008 y 2012 con una recuperación de $1200 \text{ [kg ha}^{-1}\text{]}$ en 2011; indicando que este cultivo fue sensible a las dos sequías y a la recuperación que hubo entre ambas, ver también figuras 5.2b), c) y e). Algo semejante ocurrió para el cultivo de soja pero la recuperación no fue tan efectiva como en el trigo, ver figura 4.16f) donde se ve un período de anomalías negativas, especialmente en provincia de Córdoba desde 2007 al 2013. Mientras que para el maíz, figura 4.16d), el mayor impacto negativo se produjo en 2011 y la sequía de 2008 no produjo una disminución tan marcada de los rendimientos.

5.1.1. Distribución Espacial del evento 2008/9.

Este evento seco se analiza espacialmente en las figuras 5.4 y 5.5 en su inicio y finalización respectivamente. La primera de ellas muestra el comportamiento areal de los indicadores SPI3, SEI3, SSI3 y SRI3 que corresponden al mes de julio de 2007; ya que a partir de este tiempo se identificó una abrupta caída en series temporales de los indicadores de rápida respuesta

como SEI, SRI y SPI (figuras 5.2b), c) y e)), que representa el inicio del período seco que posteriormente se registró. En figura 5.4 se ve con claridad que valores de índices entre -1 y -1,5 se extienden desde el centro de la provincia de Santa Fe hacia el sur de la cuenca para los indicadores SPI3 y SRI3. El mapa de SEI3 en la figura 5.4b) muestra mayor contundencia aún que los índices anteriores con valores deficitarios en toda la región; localizándose en Entre Ríos, Uruguay y en la costa de Buenos Aires los valores más bajos del indicador con valores de -1,5. El mapa de SSI3 solo presenta condiciones secas en la parte sur de la cuenca y en el resto de la región los valores son superiores a 0,5; este indicador aún no muestra una presencia extensa de condiciones de sequías, además la serie temporal de SSI3 presenta para la región de zona 2 condiciones por encima de 0 en figura 5.2d).

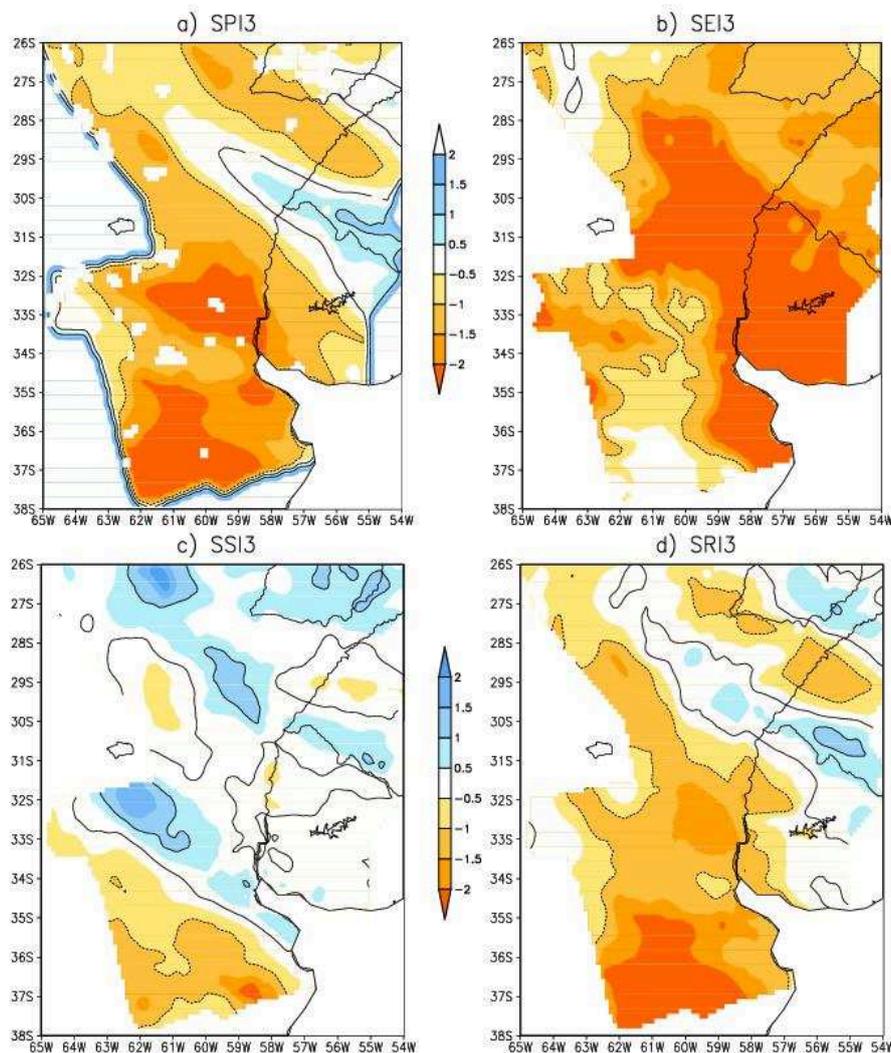


Figura 5.4: Monitoreo de eventos secos, condición de inicio de la sequía evaluada en el mes de julio de 2007 a través de: a) SPI3, b) SEI3, c) SSI3 y d) SRI3.

El evento seco detectado a mediados de 2007 se prolongó hasta 2009; las figuras 5.2b), c) y e) muestran hacia fin de 2009 valores crecientes de las series de SPI3, SEI3, y SRI3 indicando la finalización de la sequía. El índice SSI3 demoró más tiempo en recuperarse y esa recuperación fue mínima, las series temporales muestran que la recuperación solo alcanza hasta el valor -0,5 durante 2010 y luego vuelve a bajar a partir de 2011. La figura 5.5 presenta la distribución

espacial de los índices para noviembre de 2009, en este caso se muestran solo los indicadores que han evidenciado una recuperación hacia finales de 2009 como SEI y SRI, considerados para las escalas de 3 en los paneles a) y c), y 6 meses en los paneles b) y d). Todos ellos coinciden en mostrar que solo la parte sur de la cuenca persiste con condiciones secas aún, mostrando valores negativos entre -0,5 y -1, mientras que el resto de la región presenta valores neutrales o positivos como ocurre en la región norte de la Mesopotamia Argentina, Brasil y Paraguay.

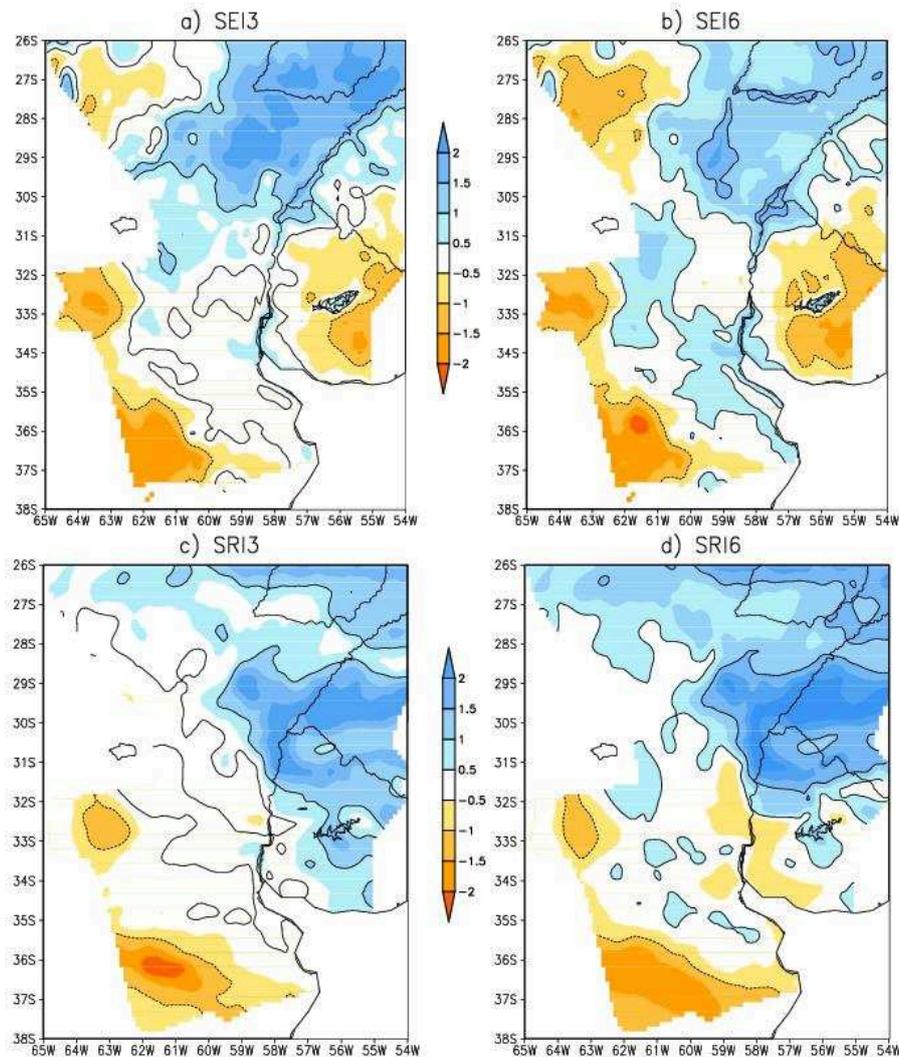


Figura 5.5: Monitoreo de eventos secos, condición de finalización de la sequía en el mes de noviembre de 2009, a través de: a) SEI3, b) SEI6, c) SRI3 y d) SRI6.

5.1.2. Distribución Espacial del evento 2011/12.

Las series temporales presentan a este evento como un episodio menos severo que el evento de 2008/9, ver figs. 5.3a)-d). Las figuras 5.2b), c) y e) muestran de acuerdo a los índices de menor escala temporal que el comienzo de este evento se produjo hacia fines del año 2010, pero al mismo tiempo se ha extendido arealmente sobre gran parte de zona 2. Para evaluar esa situación la figura 5.6 muestra la situación durante diciembre de 2010, al inicio de la sequía

de acuerdo a los indicadores SPI3, SEI3, SSI3 y SRI3. Los valores de los índices van desde moderadamente seco hasta extremadamente secos en algunos casos. Nuevamente la región sur y centro de la zona 2 presenta una región deficitaria e indicadores con los valores más bajos; todos los paneles de la figura muestran coincidentemente el centro y norte de la provincia de Buenos Aires y sur de Córdoba con valores menores a -1. El índice SSI3 es el que presenta mayor extensión de todos los indicadores de la figura, esto se debe a que este indicador es el que presenta menor fluctuación temporal de todos los analizados y aún no se ha recuperado de la previa sequía. Es destacable que tanto en la figura 5.4 como en la figura 5.6, muestran a la región del sur de la cuenca del Plata como la zona con menores valores de los índices en los inicios de las sequías 2008/9 y 2011/12, respectivamente, aunque en la primer sequía las extensiones son mayores.

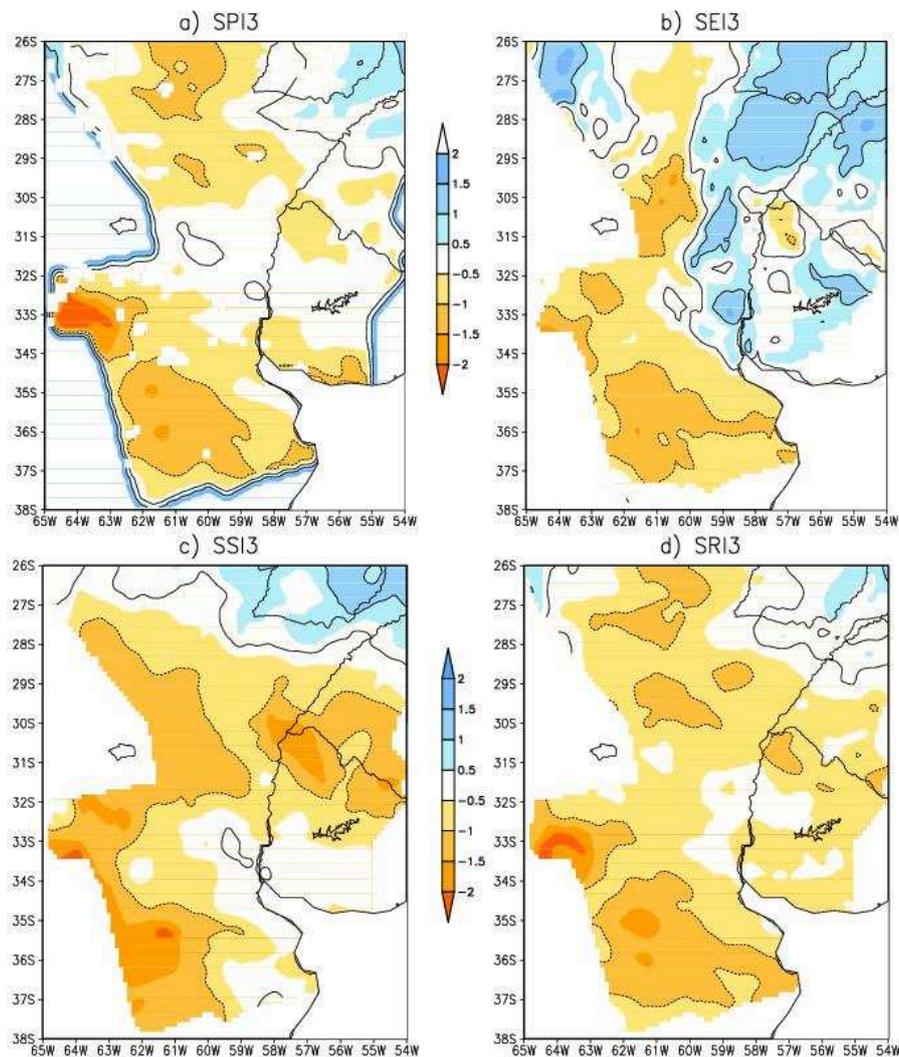


Figura 5.6: Monitoreo de eventos secos, condición de inicio de la sequía evaluada en el mes de diciembre de 2010, a través de: a) SPI3, b) SEI3, c) SSI3 y d) SRI3

Anomalías positivas cercanas a 80 [mm] en figura 5.2a) muestran condiciones de recuperación hacia fines de 2012, consecuentemente las series de los indicadores comienzan a crecer rápidamente, específicamente SPI, SRI y SSI como se ve en figuras 5.2b), d) y e). La figura 5.7 muestra la distribución espacial de los indicadores SEI3, SEI6, SRI3 y SRI6 que refieren a la

situación de noviembre de 2012. Esto indica recuperación en la región sur de la cuenca, figs. 5.7c) y d) con valores entre 0,5 y 1,0. Mientras que SEI3 y SEI6 para la misma región aún presentan zonas con déficits, y recuperación sobre el sur de Brasil.

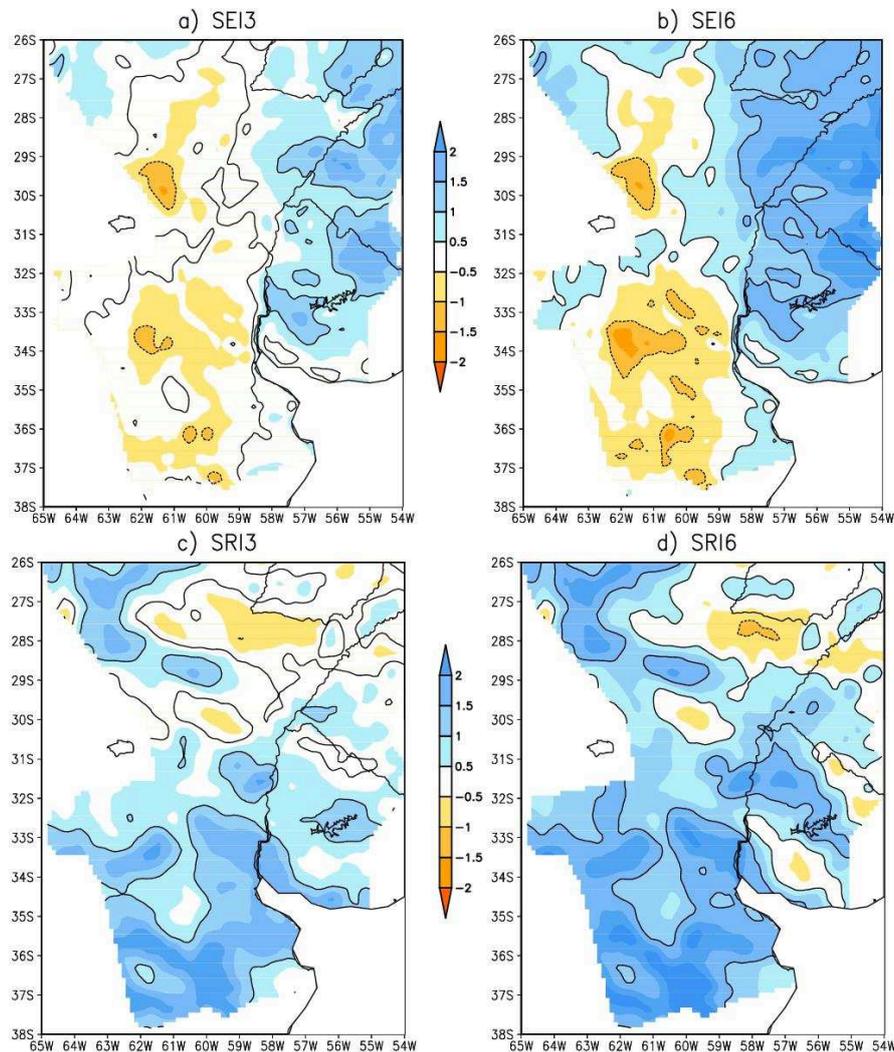


Figura 5.7: Monitoreo de eventos secos, condición de finalización de la sequía en el mes de noviembre de 2012, a través de: a) SEI3, b) SEI6, c) SRI3 y d) SRI6.

Un caso particular que ilustra las potencialidades de contar con herramientas de monitoreo de eventos secos y datos de pronósticos, en conjunto con los tomadores de decisión del área agropecuaria en esta parte de Argentina, se produjo a mediados del 2011 cuando los productores de soja y maíz planeaban las campañas en la segunda mitad de ese año para ambos cultivos. Normalmente tanto para el maíz como para la soja, las siembras se producen al comienzo de la primavera, los meses críticos de estos cultivos coinciden con la estación cálida, y las cosechas se producen entrado el otoño. Por otro lado había indicios que los efectos del evento Niña que estaba transcurriendo se verían atenuados hacia fines de 2011 (<http://ggweather.com/enso/oni.htm>) indicando una mayor probabilidad a que las precipitaciones sean normales durante el verano 2011/2012. Ante esta información organizaciones de productores, como por ejemplo AACREA (Asociación Argentina de Consorcios Regionales de Experimentación Agrícola) indicaron a los productores vinculados retrasar la siembra, conociendo la declinación del evento ENSO seco.

Con este panorama los productores que efectivamente siguieron esta alternativa, sembrando en noviembre en forma tardía, tuvieron mayores rendimientos que los que se mantuvieron en la fecha normal de septiembre (<https://blogs.iadb.org/cambioclimatico/2012/07/09/%c2%bftiene-beneficio-economico-para-usted-el-utilizar-la-informacion-climatica/>).

5.2. Pronóstico a 9 meses.

Para el desarrollo de esta parte se utilizan forzantes del modelo de superficie pronosticadas con 9 meses de antelación. Como ha sido usual en este trabajo los datos de las variables usadas como forzantes, que corresponden a datos de pronóstico operacional del CFSv2 (Saha et al., 2014), son de precipitación, temperatura máxima y mínima a 2 [m] de la superficie, y velocidades de vientos meridionales y zonales a 10 [m] de altura y todas a paso de tiempo 6-horario. Estos forzantes permiten simular condiciones a futuro de variables de superficie y de esta manera poder predecir con cierta antelación la ocurrencia de eventos extremos secos. Los pronósticos a 9 meses se inicializan 4 veces al día (a las 00hs, 06hs, 12hs y 18hs UTC) y por su carácter operacional se encuentran disponibles diariamente. Para simular las condiciones con 9 meses de anticipación se usaron los datos forzantes pronosticados, y se utilizó la condición inicial del sistema generada por el pronóstico a tiempo casi real del día correspondiente al inicio del pronóstico a 9 meses. Esta metodología permite obtener simulaciones a 9 meses a partir de la fecha de inicio del pronóstico, en la figura 5.8 se presenta un detalle del esquema de funcionamiento del sistema. Por ejemplo, siguiendo el esquema para iniciar una simulación a 9 meses desde el 1° de diciembre de 2015 se utilizan los forzantes del pronóstico a 9 meses a paso 6-horario que corresponden al día 1° de diciembre de 2015 inicializado a las 00hs UTC. Por otro lado, se genera una condición que caracteriza el estado del sistema del día 1° de diciembre de 2015, a través de una simulación utilizando los datos del pronóstico a tiempo casi real, de esta forma se obtiene para el día requerido la condición que caracteriza al sistema.

Se propone evaluar los pronósticos iniciados con datos a 9 meses, con la condición a tiempo casi real para distintos tiempos. Para esto se realizan simulaciones a 9 meses desfasadas con un mes de diferencia entre sí; de esta forma tener a un tiempo a futuro datos pronosticados pero de distintos tiempos de inicialización, y se verifican con simulaciones a tiempo casi real. Por ejemplo se propone iniciar 3 simulaciones a 9 meses: una en dic.2015, otra en ene.2016 y la tercera en feb.2016, y se evalúa el comportamiento de cada una de ellas con simulaciones a tiempo casi real hasta el mes de jun.2016. Así se tiene en la figura 5.9 una simulación generada con datos a tiempo casi real, en color negro desde fin de 2014 hasta el mes de junio de 2016 conjuntamente con tres condiciones más, una que corresponde a la simulación a 9 meses iniciada en diciembre de 2015, otra similar iniciada en enero de 2016 y la restante comenzada en febrero de 2016, en colores rojo, verde y azul respectivamente. Estos resultados fueron obtenidos a través de procesamiento de la información simulada y posterior estimación de los indicadores estandarizados para las variables precipitación y humedad del suelo mediante la metodología

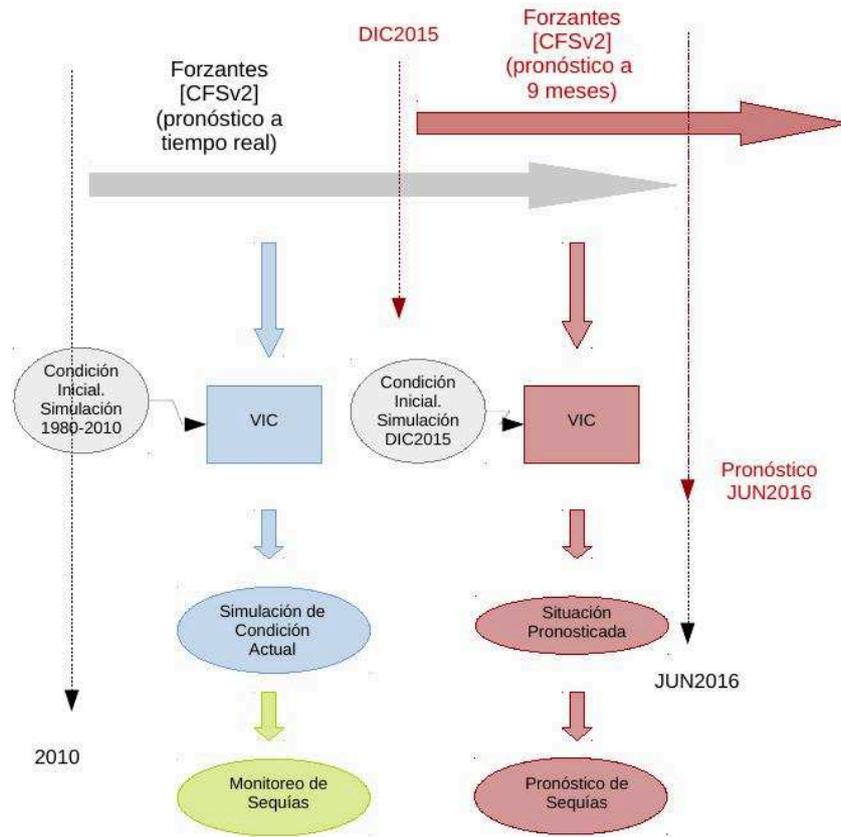


Figura 5.8: Funcionamiento del sistema de monitoreo y pronóstico basado en el Modelo VIC, a través del uso de forzantes a tiempo casi real y forzantes pronosticados a 9 meses.

ya detallada. Se determinaron las series de tiempo de cada indicador de 3 y 6 meses en la zona 2. En figura 5.9 se muestra la proyección de los indicadores pronosticados inicializados consecutivamente en distintos tiempos.

Los paneles a) y b) de figura 5.9 muestran las marchas de SPI3 y SPI6 respectivamente, en ambas escalas de tiempo la proyección del pronóstico a 9 meses que se inicia en enero de 2016 (línea verde) es la que mejor se ajusta con el comportamiento a tiempo casi real que se ve en color negro. Para SSI, en los paneles c) y d), las proyecciones y la situación a tiempo casi real presentan un acompañamiento más parejo, esto que hace que la detección de la proyección con mejor ajuste no sea fácilmente detectable como en el caso de SPI. En los dos indicadores evaluados el pronóstico mejora a medida que aumenta la escala de tiempo del indicador propuesto, es decir que SPI6 y SSI6 poseen mejor ajuste que SPI3 y SSI3 respectivamente. Por otro lado, la menor variabilidad temporal que presenta el indicador de humedad del suelo genera series de pronósticos con mejor representación que las proyecciones de SPI. Para cuantificar el ajuste y determinar la mejor aproximación entre las series pronosticadas y las mismas a tiempo casi real, se estimaron los coeficientes de determinación R^2 correspondientes y sus valores se muestran en la tabla 5.1

Los valores de los coeficientes fueron estimados considerando los períodos de tiempo comunes

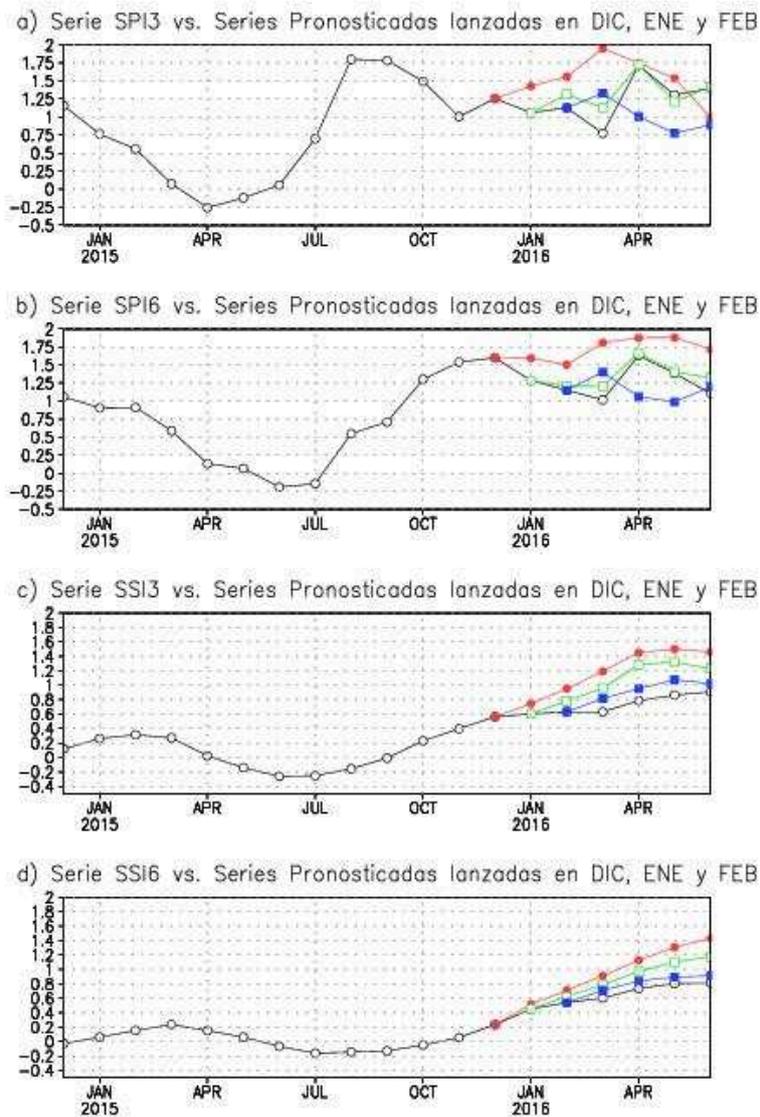


Figura 5.9: Series de tiempo con datos de pronóstico a tiempo casi real en zona 2, desde diciembre 2014 a junio 2016 para: a) SPI3 (negro). Conjuntamente con simulaciones pronosticadas a 9 meses iniciadas en dic.2015 (rojo), ene.2016 (verde) y feb.2016 (azul) del mismo indicador. b) ídem a) para SPI6, c) ídem a) para SSI3 y d) ídem a) para SSI6.

entre las series de pronósticos y las series a tiempo casi real, es decir que para estimar el valor de R^2 entre el pronóstico comenzado en diciembre 2015 y la serie a TCR se consideró desde diciembre 2015 hasta junio 2016, para el resto de los pronósticos se procedió de igual forma. De acuerdo con esto la mejor aproximación para SPI ocurre en el pronóstico iniciado en enero con coeficiente 0,76 para SPI3, y de 0,86 para SPI6. Por otro lado los indicadores SSI presentan valores más promisorios que SPI, la mejor aproximación ocurre según la serie iniciada en febrero 2016 con un coeficiente de 0,82 para SSI3, mientras que la iniciada en enero 2016 mejora aún este valor para el indicador SSI6 con 0,99.

Para evidenciar espacialmente la evolución de los pronósticos, se construyeron mapas de los indicadores SPI3 y SPI6, en la figura 5.10, que evalúan las diferencias entre las situaciones pronosticadas iniciadas en diciembre 2015, enero 2016 y febrero 2016 con la situación a TCR

	SPI3 (TCR)	SPI6 (TCR)	SSI3 (TCR)	SSI6 (TCR)
Pronóstico [dic.2015]	0,09	0,03	0,81	0,97
Pronóstico [ene.2016]	0,76	0,86	0,79	0,99
Pronóstico [feb.2016]	0,46	0,60	0,82	0,95

Cuadro 5.1: Coeficiente de correlación R^2 entre indicadores simulados a tiempo casi real (TCR) e indicadores simulados a 9 meses iniciados en dic.2015, ene.2016 y feb.2016.

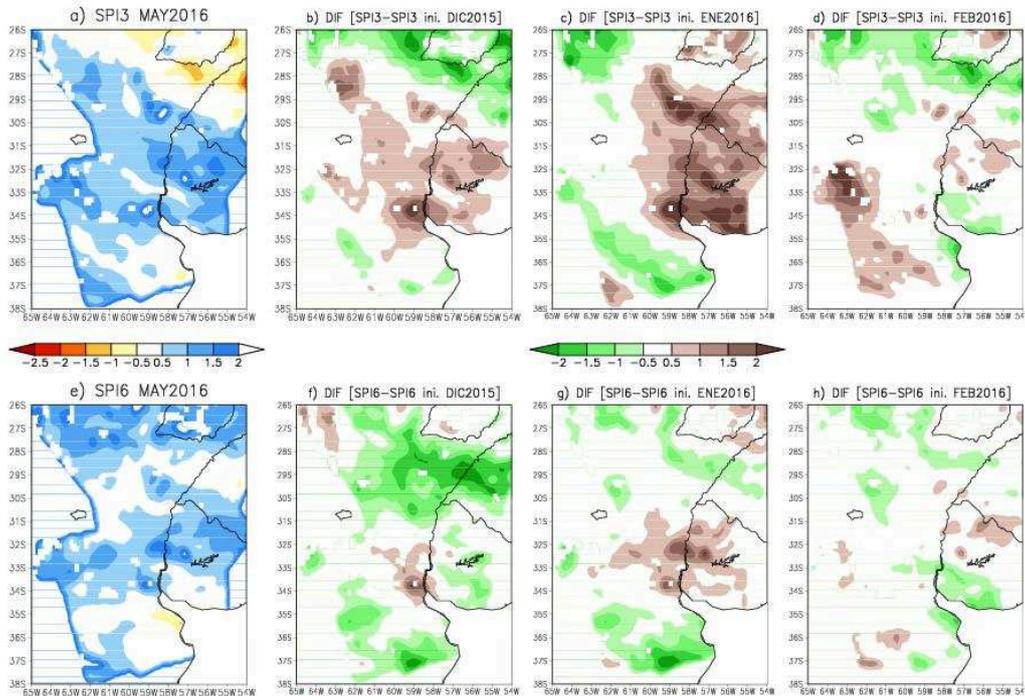


Figura 5.10: Fila 1: Diferencias entre pronóstico a tiempo casi real de a) SPI3 (MAY 2016) y pronósticos a 9 meses, iniciados en: b) dic.2015, c) ene.2016, y d) feb.2016. Fila 2: ídem fila 1 pero e), f), g), y h) refieren a SPI6.

correspondiente al mes de mayo de 2016; los pronósticos se evaluaron en el mes de mayo dado que representa una transición entre estación cálida a fría. En esta figura los colores verdes equivalen a situaciones donde se pronostica más humedad que la situación simulada a TCR (figura 5.10a)), mientras que colores marrones representan condiciones opuestas, es decir que valores de SPI de pronóstico resultan menores que los de tiempo casi real.

Durante el mes de mayo tanto SPI3 como SPI6 muestran condiciones normales a moderadamente húmedas en el centro de la zona 2, como se aprecia en figuras 5.10a) y e) respectivamente, para SPI3 las condiciones levemente húmedas se extienden también hacia el norte de la misma. Las diferencias encontradas entre la situación a tiempo casi real y los pronósticos demuestran que el mejor ajuste se obtiene con el pronóstico más reciente lanzado en febrero sobre el centro de zona 2, figs. 5.10d) y h). En contraposición con esto último, a medida que el pronóstico es más antiguo, en relación al mes de evaluación (figs. 5.10b) y f)), la representación del campo resulta más pobre y las diferencias en relación a la situación a tiempo casi real se presentan mayores. Además la representatividad espacial del pronóstico mejora con la escala de tiempo

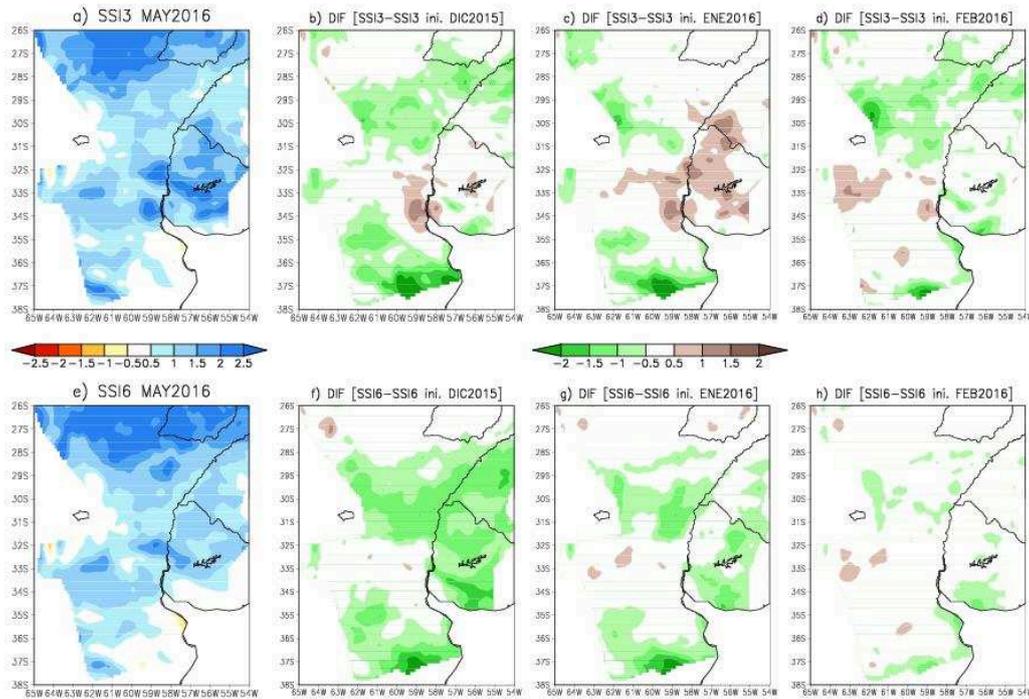


Figura 5.11: Ídem figura 5.10, pero fila 1 referido a SSI3 y fila 2 a SSI6.

del indicador, eso se evidencia en diferencias más reducidas para SPI6 sobre SPI3 en toda la región (ver figs. 5.10h) y d) respectivamente). En general los pronósticos realizados con SPI3 tienden a presentar condiciones más secas que los mismos con SPI6, en este sentido se destaca una zona de déficits marcados en la región limítrofe entre Argentina y Uruguay en la figs. 5.10b) y c), mientras que para SPI6 en dicha región el déficit es menor.

Un análisis espacial semejante para los indicadores SSI se muestra en figura 5.11 en la que se aprecian condiciones levemente más húmedas que las mostrada para los indicadores SPI, figs. 5.11a) y e). Los campos pronosticados de SSI iniciados en distintos tiempos (figs. 5.11b)-d), y 5.11f)-h)) en general tienen una mejor representación de las condiciones a tiempo casi real que los mismos pronósticos en figura 5.10. Mostrando diferencias visiblemente más reducidas en gran parte de la región del norte de Buenos Aires, sur de Santa Fe y sur de Córdoba para los indicadores estandarizados de humedad del suelo en relación a los de precipitación. Asimismo, los pronósticos de figura 5.11 presentan condiciones levemente más húmedas que los correspondientes de la figura 5.10, y solo se observan condiciones algo secas, figura 5.11c), en la zona limítrofe de Argentina Uruguay pero menores a las que se aprecian en figura 5.10c). Para la escala temporal de 6 meses el pronóstico que mejor representa las condiciones de base es el que comienza en febrero; en tanto que para SSI3 los pronósticos no difieren notoriamente entre sí, las figuras 5.11b), c) y d) tienen un comportamiento similar mostrando pronósticos levemente más húmedos en la parte sur de la cuenca.

Las situaciones de pronósticos evaluadas y sus diferencias respecto a la condición a tiempo casi real (TCR), muestran que durante el período de análisis existe una leve predisposición a simular condiciones de sequías en ciertas regiones como en la zona limítrofe entre Argentina y

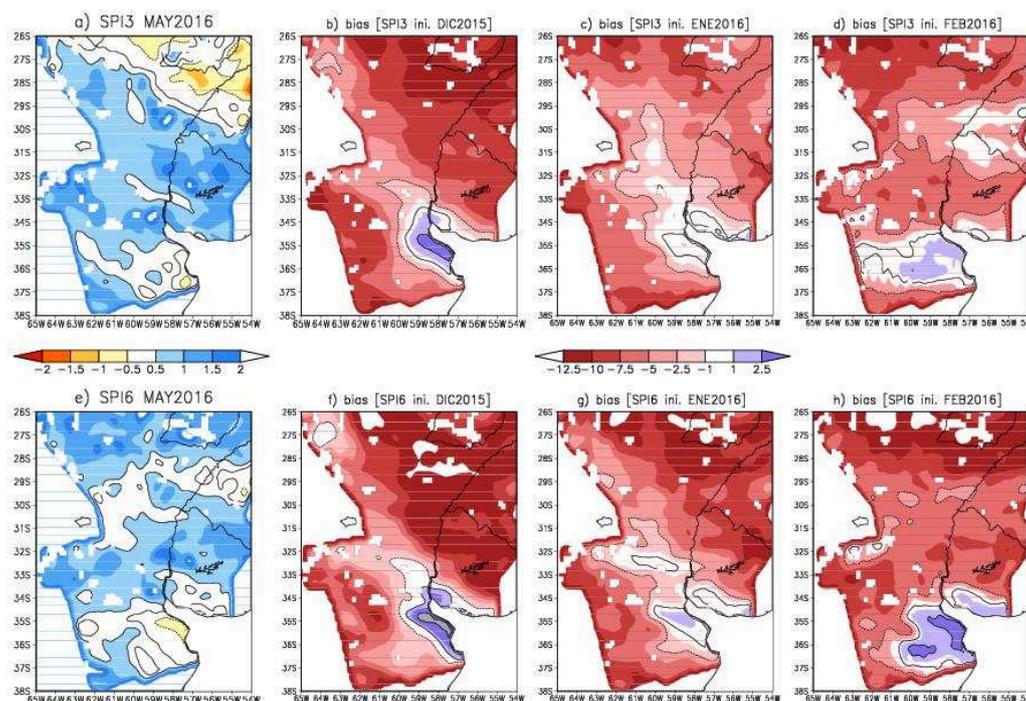


Figura 5.12: Evaluación de pronósticos en mayo 2016: Fila 1, a) situación a TCR SPI3 en mayo 2016. b) BIAS entre pronóstico a TCR y pronósticos a 9 meses iniciado en dic.2015, c) ídem a), para pronóstico iniciado en ene.2016, y d) ídem a), para pronóstico iniciado en feb.2016. Fila 2: Ídem fila 1 pero referente a SPI6.

Uruguay. Esa situación es más propensa en las simulaciones comenzadas en enero de 2016 por sobre las iniciadas en diciembre de 2015 y en febrero de 2016. Además, como se ha mencionado, el incremento de la escala de tiempo del indicador muestra condiciones menos secas en los pronósticos, esta situación se destaca principalmente en SPI pero también en menor medida en SSI.

A continuación se estimó el BIAS utilizando la fórmula (3.1), definida ya en capítulo 3, para analizar diferencias y tendencias entre los pronósticos a 9 meses versus la simulación a tiempo casi real nuevamente evaluada durante el mes de mayo, de forma análoga a lo realizado en figuras 5.10 y 5.11 para SPI y SSI respectivamente. Las estimaciones del BIAS se determinaron considerando los períodos comunes entre pronósticos iniciados en diferentes tiempos y la situación a TCR; es decir que para el pronóstico iniciado en enero de 2016 y que se evaluó en mayo 2016, el período de tiempo durante el cuál se estimó el BIAS respecto a la situación a tiempo real fue de enero a mayo. De igual forma se procedió para el pronóstico que comenzó en febrero de 2016, y también para el que comenzó en marzo de 2016; el período de tiempo de estimación del BIAS fue un mes más corto que el precedente en cada caso. Los valores del BIAS expresados en valores porcentuales para SPI se aprecian en la figura 5.12, mientras que un análisis similar se muestra para SSI en figura 5.13. Los resultados ratifican la tendencia general de los pronósticos de 9 meses a sobreestimar la condición a TCR, con valores negativos de más de 12% en la zona norte de Argentina. Esta situación resulta más marcada para el pronóstico iniciado en diciembre de 2015 y los valores del BIAS se hacen más suaves a medida

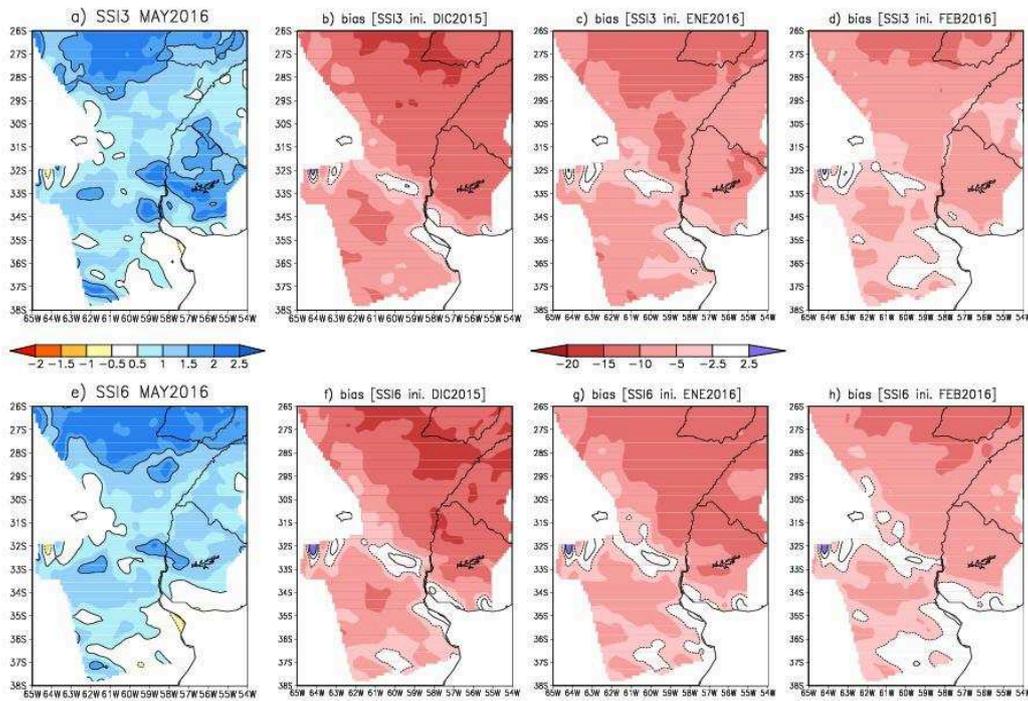


Figura 5.13: Ídem figura 5.12, pero fila 1 referido a SSI3 y fila 2 a SSI6.

que el inicio del pronóstico es más actual, ver figuras 5.12b)-d) del indicador SPI3. Aunque la situación más promisorio con menores magnitudes de BIAS se presenta para el pronóstico iniciado en enero de 2016, por sobre el iniciado en febrero del mismo año. El BIAS tienden a aumentar y hacerse positivos hacia la región del río de La Plata, en esta zona los pronósticos subestiman levemente a la situación simulada a TCR con valores cercanos al 2% positivo. Los pronósticos de SPI6 muestran una situación similar a lo mostrado para SPI3. Todos los paneles de la figura 5.12 muestran valores de BIAS entre -2,5% y 2,5% para la zona 2. Los valores de pronósticos para SSI, al igual que ocurre en figura 5.12 para SPI, presentan valores negativos remarcando la tendencia del pronóstico a sobreestimar a la situación a TCR prácticamente en toda región en este período de análisis. La zona limítrofe entre Argentina y Paraguay tiene valores de mayor magnitud entre -20% y -15%, algo más elevado que lo mostrado en figura 5.12 para esa misma zona; hacia la región de desembocadura de la cuenca el BIAS aumenta a valores entre -2,5% y 2,5%. Este análisis indica que los valores obtenidos de la evaluación de los pronósticos resultan promisorios en la zona de estudio, además este resultado es relevante dada la necesidad de contar con datos de indicadores confiables para el monitoreo de eventos secos en forma anticipada.

5.3. Conclusión.

En este capítulo se ha propuesto un sistema de pronóstico y monitoreo de eventos extremos secos en la región de estudio, que comprende el uso de un modelo hidrológico para simular condiciones de las variables de superficie a futuro cuando es forzado con variables de pronósticos a 9 meses.

Este sistema se ha usado para monitorear dos eventos extremos secos que ocurrieron en la zona de estudio y que generaron daños económicos cuantiosos especialmente en actividades relacionadas con la agricultura.

A través del monitoreo se ha permitido identificar las sequías de los eventos 2008/9 y 2011/12 en cuanto a su severidad, mediante el comportamiento de las series temporales de los indicadores evaluados a diferentes escalas de tiempo. Los indicadores de mayor variabilidad temporal como SEI3 y SPI3 son más adecuados para percibir los inicios de los eventos secos, y a pesar de que estos indicadores pueden rápidamente cambiar de situación se puede monitorear el comportamiento y desarrollo de los mismos con indicadores de respuesta más lenta como SSI3 y SSI6. Se evaluaron series de tiempo de pronóstico a 9 meses que fueron iniciados en meses consecutivos de diciembre de 2015, enero y febrero de 2016, se compararon posteriormente con series a tiempo casi real y se estimaron valores del coeficiente de determinación R^2 . La mejor aproximación entre indicadores SPI ocurrió para el pronóstico iniciado en enero con 0,76 y 0,86 para SPI3 y SPI6 respectivamente. Para SSI se obtuvieron mejores valores de R^2 que para SPI, la mejor aproximación fue con las series iniciadas en febrero 0,82 y enero 0,99 de acuerdo a SSI3 y SSI6 respectivamente.

El sistema de pronóstico a 9 meses se evaluó al mes de mayo, que representa un mes de transición entre verano e invierno. Para pronósticos iniciados en los mismos meses que para el análisis de series temporales, se evaluó el desempeño de cada uno en mayo de 2016 respecto a la simulación a tiempo casi real, utilizando indicadores SPI y SSI. El pronóstico que presenta menor diferencia respecto a la simulación a tiempo casi real es el que comienza en febrero de 2016. Esta situación se repite en todos los índices evaluados SPI3, SPI6, SSI3, y SSI6. Entre indicadores, para las simulaciones iniciadas en febrero de 2016, SSI tiene mejor pronóstico que SPI. Esto representa que el indicador de humedad del suelo que naturalmente tiene menor variabilidad temporal puede pronosticar estados con mayor habilidad que la precipitación. Los errores sistemáticos del pronóstico evaluados a través del BIAS, determinaron una tendencia a sobreestimar las condiciones a tiempo casi real en la región y esa sobreestimación se reduce hacia la zona sur de la cuenca del Plata.

Capítulo 6

Conclusiones. Discusiones y Trabajos Futuros.

6.1. Conclusiones

Durante este trabajo se ha desarrollado un sistema de alerta de eventos extremos secos a través de la implementación en la cuenca del Plata del modelo de superficie de Capacidad de Infiltración Variable, forzado con datos de pronósticos de la segunda versión del CFS (Climate forecast System v2). El sistema de alerta comprende el monitoreo de eventos secos en esta región, en particular para una zona de alta intensidad de producción de cultivos que se denomina zona 2. Incorporando datos de pronósticos estacionales referidos a los forzantes del sistema (CFSv2), se han generado mediante simulación pronósticos estacionales de variables hidrológicas de superficie que permiten establecer con anticipación a su ocurrencia, las condiciones del sistema físico y la posibilidad de detectar condiciones propias de eventos extremos secos. Esta herramienta generada constituye una alternativa más para ayudar a los tomadores de decisión en la forma de planificar sus actividades futuras en torno a la ocurrencia de las sequías y al mismo tiempo evaluar los posibles impactos.

La evaluación de la fuente de datos del reanálisis con los datos del CPC determinó, que a través de las climatologías, en la región central de la cuenca del Plata la precipitación del reanálisis subestima a los datos del análisis, mientras que en la región norte, definida como zona 1 donde hay presencia del Monzón Sudamericano, CFSR sobrestima a CPC; esto también ocurren en regiones de topografía accidentada donde los datos del análisis son consistentemente menores. En zona 1 las diferencias entre climatologías de ambas fuentes, mostraron exceso de CFSR respecto a CPC en la parte este, mientras que por defecto en la oeste; en zona 2 solo evidenciaron diferencias por defecto de CFSR. En la región norte de la cuenca los valores de correlación entre valores mensuales desde 1980 hasta 2010 entre ambas fuentes presentaron valores satisfactorios (r) de 0,7 a 0,8, siendo algo menores en la zona 2, esta última de alta

intensidad de producción de cultivos, con valores del orden de $(r) = 0,6$.

Se evaluó, también, una metodología para la construcción de índices estandarizado no paramétricos utilizando una función empírica asociada al comportamiento de la variable de precipitación. Se construyeron así índices de escalas temporales de 3 y 6 meses, resultando dichas escalas representativas de los eventos secos que ocurren frecuentemente en la cuenca; esta metodología se usó tanto en la fuente de CFSR como la de CPC. De la comparación de los indicadores SPI3 y SPI6 construidos, a través del error cuadrático medio (RMSE) se estableció que la zona 2 tiene menor error que zona 1, del orden de 0,6; mientras que zona 1 presenta valores de 0,8 y mayores en ambas escalas de tiempo. Estos valores del RMSE son satisfactorios cuando son menores o iguales a 0,5 y posiciona mejor a la zona 2 por sobre la región de la zona 1. Los valores de correlación entre las series temporales de SPI3 y SPI6 en zona 1 y 2 para ambas fuentes, mostraron mejor ajuste en la zona 2 con $(r) = 0,71$ y $0,65$ para SPI3 y SPI6 respectivamente; mientras que en zona 1 ambos indicadores obtuvieron valores muy pobres, posiblemente debido a que en esta zona las diferencias entre climatologías no es uniforme como en zona 2.

Se implementó el modelo de superficie de Capacidad de Infiltración Variable en la cuenca del Plata y se simularon en la misma los campos superficiales. Se determinó previamente a la calibración del modelo, que la profundidad de las capas de suelo resultó ser el parámetro más sensible de todos los sujetos a calibración, y la relación con la variable humedad del suelo contenida en cada una de las capas es lineal con el espesor de la misma. Durante la etapa de calibración se determinó una serie de valores de parámetros que reducen las diferencias entre las estimaciones satelitales y las simulaciones. Las funciones objetivos usadas para evaluar el desempeño del modelo en toda la cuenca, generaron valores medios de BIAS de $-4,8\%$, de SRMSE de $0,48$ y de NSE de $0,54$ que son valores satisfactorios. Estas mismas funciones determinaron valores de performance del modelo en la etapa de validación para un período más extenso y diferente del usado en la etapa previa, los valores obtenidos son BIAS de $5,5\%$, de SRMSE de $0,415$ y de NSE de $0,625$ mejorando aún a lo obtenido durante calibración. El comportamiento de las series temporales entre las estimaciones satelitales y simulaciones, tanto en las etapas de calibración como de validación, permitió destacar la habilidad que presenta la humedad del suelo simulada para representar el comportamiento dinámico de los valores correspondientes a los valores satelitales; con correlaciones de $(r) = 0,608$ y $(r) = 0,754$ en cada etapa respectivamente.

La climatología de eventos extremos secos caracterizada a través de las propiedades físicas se orientó a la región particular del sur de la cuenca del Plata, denominada zona 2, donde existe mayor actividad de producción de los cultivos de trigo, maíz y soja que representan el 60% del PBI del país. La distribución espacial de frecuencia de eventos extremos destaca que la región norte de zona 2 tiene una probabilidad mayor de que se produzcan sequías de moderadas a extremas con un valor de $0,19$, mientras que hacia el sur la probabilidad se reduce. El estudio de la duración de los eventos secos en esta zona indicó que los más frecuentes son de hasta 3 meses de duración, y que la frecuencia de los eventos disminuye a medida que aumenta

la escala temporal del indicador; pero en forma opuesta estos últimos detectaron con mayor frecuencia sequías de mayor duración. Se determinó además que las sequías de 1 mes y 2 meses de duración resultaron más frecuentes en la región limítrofe entre Argentina Brasil y Uruguay, así como también en la zona sur de la cuenca del Plata.

Las series de tiempo de extensión areal de las sequías analizadas, destacaron que los indicadores de 3 meses detectan sequías que son más extensas que las determinadas con los indicadores de mayor escala. Esta cualidad, en conjunto con el análisis de severidad indicó que la mayor escala temporal del indicador permitió determinar eventos extremos más severos que los indicadores con menor escala temporal, y que además resultaron menos extensos arealmente. El análisis de correlación entre las series de severidad y las de extensión areal permitió establecer, que los indicadores de menor variabilidad tienen mejor ajuste, indicando además que cuando un evento seco es extenso existe una posibilidad elevada de que también sea severo, ratificado con valores de $(r) = 0,85$ para SSI. Por el lado contrario cuando el indicador posee una variabilidad temporal mayor, las sequías pueden ser extensas pero esta condición no es suficiente para afirmar que las mismas sean severas.

El análisis del desempeño de los rendimientos también muestra los impactos de las sequías en la producción de cultivos y resultó ser un indicador de las pérdidas económicas en términos de la caída en el rendimiento. Las series de filtradas de rendimiento de trigo, maíz y soja presentaron disminuciones en años donde hubo eventos secos, como por ejemplo 1988/89, 1995/96 y 2008/9; esas disminuciones fueron importantes tanto en provincia de Córdoba como en Santa Fe. La correlación entre series filtradas de cultivos y series de severidad determinó que las sequías moderadas a extremas más severas produjeron menores rendimientos en los cultivos de maíz en la provincia de Córdoba, mientras que esas sequías severas en Santa Fe implicaron una mayor pérdida en el rendimiento de soja.

Se generó un sistema de monitoreo y pronóstico de eventos extremos secos que utiliza forzantes pronosticadas y el modelo hidrológico de superficie para obtener campos de variables superficiales. Este sistema se ha usado para monitorear dos eventos extremos secos que ocurrieron en la zona de estudio y que generaron daños económicos cuantiosos especialmente relacionados con actividades agrícolas. Se identificaron las sequías de los eventos 2008/9 y 2011/12 por su severidad a través de las marchas de los indicadores, estableciéndose que los de mayor variabilidad temporal, como SEI3 y SPI3, perciben mejor los inicios de lo eventos secos, mientras que los de respuesta más lenta como SSI3 y SSI6 detectan mejor su desarrollo y persistencia.

Las series de pronóstico a 9 meses iniciadas en tiempos consecutivos (diciembre, enero y febrero) se compararon en los períodos coincidentes con la series a tiempo casi real a través del coeficiente de determinación R^2 . El mejor ajuste ocurrió para el pronóstico iniciado en enero con 0,76 y 0,86 para SPI3 y SPI6 respectivamente. Para SSI los resultados obtenidos son mejores, en febrero $R^2 = 0,82$ para SSI3 y enero $R^2 = 0,99$ para SSI6. El pronóstico que presenta menor diferencia en zona 2 respecto a la simulación a tiempo casi real es el que comienza en febrero de 2016; esta

situación se replicó en todos los índices evaluados SPI3, SPI6, SSI3 y SSI6. Entre indicadores, para las simulaciones lanzadas en febrero, SSI tiene mejor pronóstico que SPI; esto implica que el indicador de humedad del suelo, que tiene menor variabilidad temporal que la precipitación, permite pronosticar estados del sistema con mayor habilidad que los índices construidos en base a esta última. Los errores sistemáticos del pronóstico, evaluados a través del BIAS, determinaron una tendencia a sobreestimar las condiciones a tiempo casi real, particularmente en la región norte de la zona 2 con valores de -12% para SPI y algo mayores cerca de -15% para SSI; esa sobreestimación se reduce haciéndose más positiva hacia la zona sur de la cuenca del Plata, donde los valores son de entre -2,5% y 2,5%.

6.2. Discusión y Trabajo a Futuro.

Durante la primera parte del capítulo 2 se ha abordado una forma de evaluar las diferencias que presentan los valores de precipitación del reanálisis y los de origen observado. Se establecieron diferencias a distintas escalas temporales, el grado de vinculación, y se determinaron también las regiones donde los datos del reanálisis y del CPC tienen mejor ajuste. Se establecieron valores de buena correlación en la región del Monzón de Sudamérica cercanos a $(r) = 0,8$ donde el ciclo anual es bien marcado. Descendiendo geográficamente hacia el sur de la cuenca, la correlación era menor y del orden de $(r) = 0,6$. Esto permite, por un lado, detectar la certeza de los valores de CFSR en relación a los datos de CPC; sino también abre una línea para investigar las incertezas de los campos simulados con el modelo VIC en el SESA cuando se utiliza la precipitación del CPC como forzante. La metodología aplicada en esta tesis utiliza como forzantes del modelo de superficie regional, datos de un modelo global de reanálisis no exento de errores. Una manera para estimar la incertidumbre de esta metodología, sería incorporar como forzante al modelo de superficie datos de precipitación basados en observaciones, como los de CPC, en vez de los datos de precipitación del reanálisis; de esta forma poder evaluar las diferencias entre simulaciones y analizar la incertidumbre. Esto va más allá del trabajo presentado en esta tesis, y se propone como trabajo a futuro investigar la reducción de las incertidumbres con esta modificación de la metodología.

Un punto a destacar sobre este trabajo es acerca de las etapas de calibración y validación del modelo de superficie, ya que ambas fueron realizadas con datos de humedad del suelo proveniente de estimaciones satelitales. Si bien estos datos satelitales usados provienen de un producto general global, que genera valores de humedad del suelo mediante el uso de un algoritmo que procesa tanto las estimaciones de sensores pasivos como activos; el valor final obtenido solo es representativo del contenido en la porción superior del mismo que solo es de unos pocos centímetros de profundidad. En consecuencia los parámetros del modelo VIC se definieron considerando los datos de humedad del suelo que corresponden a ese espesor de suelo donde el satélite es efectivo en la medición, y no exento de errores; con lo cual la pregunta que subyace es: podrían ser representativos los parámetros del modelo cuando fueron calibrados con el con-

tenido de humedad de la porción superficial? Más aún cuando el esquema de profundidad que presenta el mismo considera al suelo dividido en 3 capas de distintos espesores, y que sobrepasa los 2 metros en total. Los resultados y la evaluación han demostrado que la representatividad del modelo, para simular condiciones y comportamientos de las variables de superficie ante la ocurrencia de eventos extremos secos, es aceptable y está cuantificado, pero los resultados se pueden mejorar. Hay datos existentes y disponibles de mediciones de humedad del suelo a profundidades mayores lo que haría más representativo lo que ocurre en el esquema de suelo del modelo; estos datos pueden utilizarse para calibrar el modelo y evaluar si la habilidad en la detección de eventos secos mejora.

Otro punto interesante es acerca de las bondades de predictivas de los productos usados en este trabajo; es decir si los productos del CFS, específicamente los datos del pronóstico (tanto a tiempo casi real como a 9 meses), poseen habilidades de predecir los estados del sistema mejor que un sistema de ensamble de modelos ESP (Ensemble Prediction System). Esto último no es un tema cerrado. Discusiones a cerca de las habilidades predictivas y de los errores sistemáticos del CFSv2 en regiones de América del Norte han sido presentadas en trabajos como por ejemplo Mo et al. (2012) y Dirmeyer y Tawfik (2013), y también a nivel global en Dirmeyer (2013). En particular en este último se estableció una evolución del error sistemático con el tiempo del pronóstico, particularmente con la precipitación y en menor medida para otras variables. En este sentido como la habilidad de predicción del modelo disminuye a medida que avanza el tiempo de pronóstico, es decir a mayor horizonte de pronóstico mayor es el error, es necesario contar con mejor información estacional de los modelos predictivos globales de manera que puedan proveer información más confiable a los modelos hidrológicos, y de esta forma predecir comportamientos estacionales de las variables de superficie. Por último, el estudio de la performance de los modelos superficiales como VIC, NOAH y otros, es un tema aun abierto en la comunidad científica; cada modelo muestra ventajas y desventajas, por lo que en muchos casos se emplea un ensamble de modelos para reducir los errores.

Además de lo establecido en la discusión, se propone a futuro implementar un sistema de ruteo de los excedentes hidrológicos ya estimados con VIC, que permita determinar valores de caudales en donde haya estaciones de aforos. Con dos objetivos básicos: Por un lado verificar los parámetros de suelo establecidos en calibración, utilizando algoritmos de optimización entre simulaciones y observaciones. En segundo término, evaluar el grado de ajuste entre los caudales simulados y observados en la estación de aforo, y así también agregar al sistema de pronóstico y monitoreo generado, información sobre el comportamiento del caudal en la estación de aforo. Entre otras cosas esto permitirá tener una validación constante del modelo implementado. También se considera incorporar en la evaluación de eventos extremos secos al indicador SPEI, como indicador adicional a los ya analizados en el sistema de pronóstico y monitoreo; este indicador permitirá estimar la cantidad de agua almacenada en superficie y conjuntamente analizarlo con los indicadores de rendimiento de los cultivos.

Appendix A

Anexo.

A.1. Balance de Agua

Las formas de funcionamiento del modelo dan la posibilidad que el mismo se pueda usar resolviendo la ecuación de balance hidrológico solamente, o resolviendo en una misma simulación las ecuaciones de balance hidrológico y de balance de energía. Para la segunda opción se requiere que el paso de tiempo de la simulación sea a subdiario. La ecuación que representa cómo se distribuye el agua que precipita sobre una superficie de terreno desprovisto de vegetación es la ecuación A.1, donde el lado izquierdo de la igualdad corresponde a la variación temporal del agua almacenada, mientras que del lado derecho representan los cambios en la precipitación, la evaporación total y la escorrentía respectivamente en cada paso de tiempo.

$$\frac{\partial S}{\partial t} = P - E - R \quad (\text{A.1})$$

$$\frac{\partial W_i}{\partial t} = P - E_c - P_g \quad (\text{A.2})$$

Cuando el agua precipita sobre una región con cobertura vegetal, la ecuación presenta una ligera modificación A.2, W_i es la cantidad de agua almacenada por el canopeo, E_c es la evaporación del agua almacenada en el canopeo, y P_g es la parte de la precipitación que escurre por el canopeo y llega al suelo. La unidad de todas las variables es (mm) para cada paso de tiempo.

Como se mencionó con anterioridad en el modelo *VIC* consideran tres tipos de evaporación, la evaporación del agua almacenada en el suelo desnudo E_v (mm), la evapotranspiración de las raíces de la vegetación E_t (mm), y la evaporación del agua almacenada en el canopeo E_c (mm). La evaporación total (E) es la suma de cada término ponderado por la fracción de cobertura correspondiente, de acuerdo a la siguiente fórmula.

$$E = \sum_{n=1}^{N+1} C_n (E_c + E_t) + C_{N+1} E_v$$

$$\sum_{n=1}^{N+1} C_n = 1$$

Cada una de las distintas expresiones de evaporación tiene en su fórmula la expresión de la evaporación potencial de *Penman – Monteith*, fórmula A.3 (Shuttleworth, 1993) expresada en (mm).

$$E_p = \frac{\Delta(R_n - G) + \rho_a C_p D r_a}{\Delta + \gamma} \quad (\text{A.3})$$

donde D es el déficit de presión de vapor de aire, G es flujo de calor del suelo, R_n es la radiación neta, Δ es la relación entre la presión de vapor de saturación y la temperatura del aire, γ es la constante psicrométrica, ρ_a es la densidad del aire, r_a es la resistencia atmosférica y c_p es el calor específico.

A.1.1. Evaporación del Canopeo

El agua que precipita y cae sobre las hojas de la vegetación en parte queda almacenada en el canopeo y otra parte excedente escurre a través de los tallos y troncos hasta llegar al suelo (*throughfall*). Si existen las condiciones adecuadas la que queda retenida por las hojas se evapora a la máxima tasa. Esta evaporación se estima de la siguiente forma, de acuerdo a Liang et al. (1994).

$$E_c^* = C^{2/3} E_p \frac{r_w}{r_w + r_0} \quad (\text{A.4})$$

donde C es un coeficiente que relaciona la cantidad de agua interceptada por el canopeo sobre la máxima que puede interceptar, E_p es la evaporación potencial de Penman-Monteith, r_w es la resistencia aerodinámica a la transferencia de agua, y r_0 es la variación del gradiente de humedad específica entre las hojas del canopeo y el aire circundante. Cada uno de estos término varía según el tipo de vegetación. Cuando las condiciones de la intensidad de precipitación sea menor que la máxima tasa a la que puede evaporar (fórmula A.4); no existe suficiente cantidad de agua almacenada sobre la vegetación para poder evaporar, en consecuencia se debe afectar a la ecuación A.4 por un coeficiente $f < 1$, donde f es la fracción del paso de tiempo que le toma a la evaporación consumir el agua almacenada en el canopeo. En este caso la ecuación A.4 queda de la siguiente manera:

$$E_c = f E_c^* \quad (\text{A.5})$$

A.1.2. Transpiración de la Vegetación

La transpiración de cada clase de vegetación que se encuentre en la celda consiste en la suma de la transpiración de todas las capas de suelo que contenga raíces de la vegetación, ponderada por el porcentaje que ocupa la raíz en cada capa de suelo. La forma de estimar la transpiración extraída de cada capa de suelo, según Liang et al. (1994) es como sigue:

$$E_t = E_p \frac{r_w}{r_w + r_0 + r_c} [(1 - f) + f (1 - C^{2/3})] \quad (\text{A.6})$$

donde C , E_p , r_0 , r_w y f son los mismos términos que aparecen en fórmula A.4, mientras que r_c es la resistencia del canopeo que describe cómo es el flujo de vapor a través de la transpiración de la vegetación y de la evaporación del suelo. En la ecuación A.6 el primer término dentro del corchete refiere a la fracción del paso de tiempo donde solo hay transpiración de la vegetación pero no evaporación del canopeo, mientras que el segundo término representa la fracción del paso de tiempo donde existen los dos procesos anteriores. Luego para hallar la transpiración producida en todas las capas de suelo, considerando que las tres capas contienen raíces en su interior, la transpiración total se obtiene aplicando la fórmula A.6 ponderada por la fracción de raíz que contiene cada capa del suelo.

$$E_t(n) = f_1(n)E_t^1(n) + f_2(n)E_t^2(n) + f_3(n)E_t^3(n) \quad (\text{A.7})$$

En la ecuación A.7, f_1 , f_2 , y f_3 refieren a las fracciones de cada capa de suelo que contienen raíces de vegetación. Mientras que la transpiración en las capas superior, intermedia, e inferior, la constituyen E_t^1 , E_t^2 , y E_t^3 , respectivamente, y (n) es la clase de vegetación.

A.1.3. Evaporación del Suelo Desnudo

Esta evaporación solo ocurre en la zona de la celda donde no existe vegetación, y solo la cantidad de agua que se encuentra en la primer capa de suelo es extraída por evaporación. Cuando esa primer capa se encuentra saturada la evaporación ocurre a la máxima tasa posible, luego $E_v = E_p$. Si esa primer capa no se encuentra saturada, la tasa de evaporación se determina usando la expresión de Franchini y Pacciani (1991) que utiliza la estructura del modelo de *Xinanjian* (Zhao et al., 1980, Wood et al., 1992) que establece que la capacidad de infiltración varía arealmente dentro de la celda de acuerdo a la fórmula A.8.

$$i = i_m [1 - (1 - A)^{1/b_i}] \quad (\text{A.8})$$

En la misma A es la fracción del área de la celda donde la capacidad de infiltración es menor que i , b_i es la constante de forma de la curva y se encarga de darle variabilidad espacial a la capacidad de infiltración, y i_m es la máxima capacidad de infiltración que se estima de la siguiente manera:

$$i_m = [1 + b_i] \theta_s |z|$$

Donde z es el espesor de la capa de suelo y θ_s la porosidad del suelo, ambas correspondientes a la capa superior. La expresión para determinar la evaporación total del suelo desnudo es:

$$E_v = E_p \left[\int_0^{A_s} dA + \int_{A_s}^1 \frac{i_0}{i_m [1 - (1 - A)^{1/b_i}]} dA \right] \quad (\text{A.9})$$

En la ecuación A.9, la primer integral corresponde al área de la celda que se encuentra saturada A_s y evapora a la máxima tasa, mientras que la segunda integral refiere a la porción no saturada, i_0 es la capacidad de infiltración específica de A.8 que se corresponde con la humedad de suelo de la celda a tiempo 0. La curva que representa la variabilidad de la capacidad de infiltración para una celda genérica, sigue el modelo Xianjiang (Zhao et al., 1980, Wood et al., 1992) y se muestra en la figura 3.2.

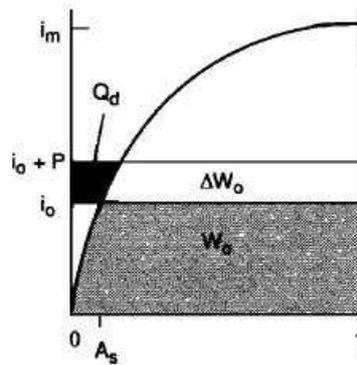


Figura A.1: Curva de capacidad de infiltración variable del modelo *Xianjiang* (Wood et al., 1992).

A.1.4. Escurrimiento Directo y Flujo Base

La generación del escurrimiento directo Q_D (R) se realiza mediante el uso de la curva de capacidad de infiltración variable (Zhao et al., 1980; 1992), el Q_d se genera por las capas de suelo superior e intermedia. La capacidad de infiltración de la celda correspondiente a la

humedad del suelo (W_0) para el paso de tiempo previo es i_0 , si a esa humedad residual se le agrega precipitación P y esta excede la capacidad de almacenamiento del suelo se genera el escurrimiento directo Q_D . El área de la celda que se asocia con i_0 es A_S y es la porción de la celda que se encuentra saturada, que ya no puede infiltrar más, y por lo tanto la que bajo estas condiciones genera Q_D . La máxima cantidad de agua que puede contener el suelo está dada por W_c que es equivalente a $\theta_s |z|$ y representa al volumen efectivo de agua de toda la capa de suelo considerada. El parámetro b_i es un valor constante para toda la celda, da una idea de la capacidad de infiltración en función del área saturada de la celda y constituye un parámetro de ajuste del modelo, su rango de valores va desde $[\sim 0,10]$ de acuerdo a Xie et al., (2006). Un valor alto de b_i genera baja infiltración y alto escurrimiento directo.

$$W_c = \frac{i_m}{1 + b_i}$$

El escurrimiento directo se determina de la siguiente forma.

$$Q_D = P - W_c + W_o \text{ cuando } (i_0 + P) \geq i_m$$

$$Q_D = P - W_c + W_o + W_c \left[1 - \frac{i_0 + P}{i_m} \right]^{1+b_i} \text{ cuando } (i_0 + P) < i_m \quad (\text{A.10})$$

El flujo base Q_b (B) es generado solo por la capa de suelo más profunda siguiendo el concepto del modelo de flujo base no lineal de *Arno* (Franchini y Pacciani, 1991; Todini, 1996), el mismo utiliza la curva de flujo base que se ve en porción inferior de la figura 3.1 para su cálculo. Considera que la generación del flujo base es lineal con la humedad del suelo contenida por esta capa, hasta un cierto valor de humedad del suelo y a partir del cual, al incrementarse la cantidad de humedad, la generación del flujo base es no lineal. La forma de estimación de Q_b se muestra en la ecuación:

$$Q_b = \frac{D_s D_m}{W_s \theta_s} \theta_3 \text{ cuando } 0 \leq \theta_3 \leq W_s \theta_s$$

$$Q_b = \frac{D_s D_m}{W_s \theta_s} \theta_3 + \left[D_s - \frac{D_s D_m}{W_s} \right] \left[\frac{\theta_3 - W_s \theta_s}{\theta_s - W_s \theta_s} \right] \text{ cuando } \theta_3 > W_s \theta_s \quad (\text{A.11})$$

En la fórmula A.11 D_m representa la máxima velocidad ($mm \text{ d}^{-1}$) del flujo base, D_s es una fracción del máximo flujo base, W_s es una porción del máximo contenido de humedad de suelo a partir del cual comienza el flujo base no lineal, θ_s es la porosidad del suelo, θ_3 es el contenido volumétrico de humedad de la capa inferior. La curva de flujo base es no lineal a partir del contenido de humedad mayor a $W_s \theta_s$ y es lineal cuando θ_3 se encuentra debajo de ese umbral.

Finalmente el escurrimiento total Q surge de considerar las ecuaciones A.10 y A.11 que se generan en una celda de con $N + 1$ tipos de coberturas (incluyendo el suelo desnudo). Entonces el caudal total generado es:

$$Q = \sum_{n=1}^{N+1} C_n(Q_{D,n} + Q_{b,n}) \quad (\text{A.12})$$

A.1.5. Humedad del suelo

En su funcionamiento el modelo hidrológico *VIC* considera que no existe flujo lateral entre celdas y que solo existen movimientos en una dirección. En consecuencia la variación temporal de la humedad del suelo en cada capa puede ser determinada mediante la aplicación de la ecuación de *Richards* en una sola dimensión, la del movimiento vertical. En dicha ecuación, la suma de un término de movimiento del agua por difusión más un término de movimiento de agua por gravedad permite obtener la variación del contenido volumétrico de agua en cada capa. La ecuación de Richards es como sigue:

$$\frac{\partial \theta}{\partial t} = \frac{\partial}{\partial z} \left(D(\theta) \frac{\partial \theta}{\partial z} \right) + \frac{\partial K(\theta)}{\partial z} \quad (\text{A.13})$$

En donde $D(\theta)$ es el término de difusión del agua en el suelo en ($mm^2 d^{-1}$), $K(\theta)$ es la conductividad hidráulica en ($mm d^{-1}$), z es la profundidad de la capa de suelo en (m), y θ es el contenido volumétrico de agua en el suelo. Integrando la ecuación A.13 se obtiene el contenido volumétrico de agua en el suelo (Mahrt y Pan, 1984), entonces para las capas superior e intermedias de suelo la expresión de θ se obtiene de la siguiente forma:

$$\begin{aligned} \frac{\partial \theta_i}{\partial t} z_i &= I - E - K(\theta)|_{-z_i} + D(\theta) \frac{\partial(\theta)}{\partial z} |_{-z_i} \\ \theta_i &= \frac{1}{z_i} \int_{-z_i}^0 \theta dz \text{ con } i = 1, 2 \end{aligned} \quad (\text{A.14})$$

Donde I es la tasa de infiltración ($mm d^{-1}$) que se obtiene por la diferencia entre la P y el Q_D en el caso de suelo desnudo, si tuviese cobertura vegetal se toma el valor de P_g en vez de P . Los valores de z_1 y z_2 son las profundidades en (m) de las capas de suelo primera y segunda respectivamente y E es el valor de la evaporación total ($mm d^{-1}$). Si ambas capas se encuentran saturadas el término difusivo se anula y toda el agua se mueve por gravedad $K(\theta)$ desde la capa superior. Si en cambio ninguna se encuentra saturada el término difusivo aporta humedad desde la capa de mayor contenido volumétrico hacia la que tiene menos (Liang et al., 1996). Para la última capa de suelo se considera que hay drenaje (aporte) desde la capa intermedia y desde

esta capa hay salida como flujo base Q_b , en consecuencia el balance de humedad del suelo en la capa inferior responde a:

$$\frac{\partial \theta_3}{\partial t} (z_3 - z_2) = -Q_b - E + K(\theta)|_{-z_2} + D(\theta) \frac{\partial(\theta)}{\partial z} |_{-z_2}$$

$$\theta_3 = \frac{1}{(z_3 - z_2)} \int_{-z_2}^{-z_3} \theta dz \quad (\text{A.15})$$

Para el caso que sea suelo desnudo el término de la evaporación total es nulo, porque no hay raíces de vegetación que puedan extraer humedad.

A.2. Balance de Energía

Cada uno de los $N + 1$ tipos de cobertura, incluyendo el suelo desnudo, que se esquematiza en la figura 3.1 actúan en forma conjunta para el balance de agua y balance de energía, y responde de acuerdo a sus propiedades térmicas (Liang et al., 1994). La ecuación del balance de energía A.16 representa el comportamiento termal para cada cobertura.

$$R_n = H + \rho_w L_e E + G \quad (\text{A.16})$$

En la cual H es el flujo de calor sensible ($W m^{-2}$), G es el flujo de calor de la superficie del suelo, E es la evaporación total, L_e es el calor latente de vaporización ($J kg^{-1}$) y ρ_w es la densidad del agua ($kg m^{-3}$); el valor que se obtiene R_n es la radiación neta ($W m^{-2}$). El producto de los término $\rho_w L_e E$ representa el flujo de calor latente ($W m^{-2}$). Cuando la superficie del terreno es relativamente es plana y homogénea, la ecuación de energía para una parcela de aire adyacente al suelo se expresa como:

$$R_n = H + \rho_w L_e E + G + \Delta H_s$$

Donde el último término representa el cambio de energía almacenado en la parcela de aire ($W m^{-2}$). La radiación neta y los flujos de calor latente y sensible son referidos al tope de la parcela de aire, mientras que G es referido a la base de la misma. Los balances de agua y de energía se vinculan mediante el calor latente, que equivale a la evaporación total determinada en el balance de agua, expresada en unidades de energía.

El calor sensible H es obtenido de la siguiente expresión:

$$H = \frac{\rho_a c_p}{r_h} (T_s - T_a)$$

Mientras que el flujo de calor del suelo es

$$G = \frac{k}{d_1} (T_s - T_1)$$

Donde T_s y T_a son las temperaturas de la superficie y temperatura del aire ($^{\circ}K$) respectivamente, r_h es la resistencia aerodinámica del flujo de calor ($s\ m^{-1}$), c_p es el calor específico del aire a presión constante ($J\ kg^{-1}k^{-1}$), k es la conductividad térmica del suelo ($W\ m^{-1}k^{-1}$), T_1 es la temperatura del suelo a la profundidad de suelo $d_1(m)$.

Bibliografía

- [1] Ameghino, F. (1884), Las secas y las inundaciones en la Provincia de Buenos Aires. Obras de retención y no de desagüe, *Publicaciones del Ministerio de Asuntos Agrarios*, Buenos Aires, La Plata.
- [2] Barrucand, M. G., Vargas, W. M., y Rusticucci, M. M. (2007), Dry conditions over Argentina and the related monthly circulation patterns, *Meteorology and Atmospheric Physics*, 98(1-2), 99–114.
- [3] Berbery, E. H., y Barros, V. R. (2002), The hydrologic cycle of the La Plata basin in South America, *Journal of Hydrometeorology*, 3(6), 630–645.
- [4] Berbery, E. H., Doyle, M., y Barros, V. (2006), Regional precipitation trends. Climate change in the La Plata basin, (Ed): Barros V., R. Clarke y P. Silva Días, Buenos Aires, CIMA/CONICET-UBA, 61–73.
- [5] Bert, F. E., Satorre, E. H., Toranzo, F. R., y Podestá, G. P. (2006), Climatic information and decision-making in maize crop production systems of the Argentinean Pampas, *Agricultural Systems*, 88(2), 180–204.
- [6] Bidegain, M., 2009, Severe drought in central Argentina and Uruguay [in “State of the Climate in 2008”], *Bull. Amer. Meteor. Soc.*, 90(8), S138.
- [7] Blain, G. C. (2011). Standardized precipitation index based on Pearson type III distribution, *Revista Brasileira de Meteorologia*, 26(2), 167–180.
- [8] Blacutt, L. A., Herdies, D. L., de Gonçalves, L. G. G., Vila, D. A., y Andrade, M. (2015). Precipitation comparison for the CFSR, MERRA, TRMM3B42 and combined scheme datasets in Bolivia, *Atmospheric Research*, 163, 117–131.
- [9] Byun, H. R. y Wilhite, D.A. (1999), Objective quantification of drought severity and duration, *J. Clim.*, 12, 2747–2756.
- [10] Byun, H. R. y Kim, D. W. (2010). Comparing the effective drought index and the standardized precipitation index, *Economics of drought and drought preparedness in a climate change context*. López-Francos A.(comp.), López-Francos A.(collab.). *Options Méditerranéennes. Sér. A. Séminaires Méditerranéens*, (95), 85–89.

- [11] Castañeda, M., y Barros, V. (2001), Tendencias de la precipitación en el oeste de Argentina, *Meteorológica*, 26(1), 5–23.
- [12] CECR. (2012), Comprehensive Error Characterisation Report, Version 0.7, 21 May 2012, ESA Climate Change Initiative Phase 1 Soil Moisture Project, <http://www.esa-soilmoisture-cci.org/node/119>.
- [13] Chen, F., y Dudhia, J. (2001), Coupling an advanced land surface–hydrology model with the Penn State–NCAR MM5 modeling system. Part I: Model implementation and sensitivity, *Monthly Weather Review*, 129(4), 569–585.
- [14] Chen, M., y Xie, P. (2008), Quality Control of Daily Precipitation Reports at NOAA/CPC, *paper presented at AMS 12th conference on IOAS-AOLS*, 20-24 January New Orleans, viewed 3 March 2015.
- [15] Chen, M., Shi, W., Xie, P., Silva, V., Kousky, V. E., Wayne Higgins, R., y Janowiak, J. E. (2008), Assessing objective techniques for gauge-based analyses of global daily precipitation, *J. Geophys. Res.*, 113, D04110, doi:10.1029/2007JD009132.
- [16] Chen, J. L., Wilson, C. R., Tapley, B. D., Longuevergne, L., Yang, Z. L., y Scanlon, B. R. (2010), Recent La Plata basin drought conditions observed by satellite gravimetry, *J. Geophys. Res.*, 115, D22108, doi:10.1029/2010JD014689.
- [17] Cherkauer, K. A., Bowling, L. C., y Lettenmaier, D. P. (2003), Variable infiltration capacity cold land process model updates, *Global and Planetary Change*, 38(1), 151–159.
- [18] Corti, A. F., y Mendoza Gallo, L. (2012), Informe Impacto de la Sequía en el norte de Santa Fe – Abril de 2009, *EEA INTA Reconquista*, 41 pp.
- [19] Cosby, B. J., Hornberger, G. M., Clapp, R. B., y Ginn, T. (1984), A statistical exploration of the relationships of soil moisture characteristics to the physical properties of soils, *Water Resources Research*, 20(6), 682–690.
- [20] Cruzate, G. A., y Casas, R. (2012), Extracción y balance de nutrientes en los suelos agrícolas de la Argentina, *Informaciones Agronómicas de Hispanoamérica*, 6, 7–14.
- [21] Dai, A. (2011). Drought under global warming: a review, *Wiley Interdisciplinary Reviews: Climate Change*, 2(1), 45–65.
- [22] D’Ambrosio, G. T., Bohn, V. Y., y Piccolo, M. (2013). Evaluación de la sequía 2008-2009 en el oeste de la Región Pampeana (Argentina), *Cuadernos Geográficos*, (52).
- [23] Dee, D. P., Uppala, S. M., Simmons, A. J., Berrisford, P., Poli, P., Kobayashi, S., ..., y Bechtold, P. (2011), The ERA-Interim reanalysis: Configuration and performance of the data assimilation system, *Quarterly Journal of the royal meteorological society*, 137(656), 553–597.

- [24] Díaz-Zorita, M. (2012) Soil productivity from the sandy pampas region under the present agricultural conditions, *Agrociencia*, 16(3), 84–88.
- [25] Dracup, J. A., K. S. Lee, y E. G. Paulson. (1980), On the definition of droughts, *Water Resour. Res.*, 16, 297–302.
- [26] Draper, C. S., Walker, J. P., Steinle, P. J., De Jeu, R. A., y Holmes, T. R. (2009), An evaluation of AMSR–E derived soil moisture over Australia, *Remote Sensing of Environment*, 113(4), 703–710.
- [27] D’Odorico, P., Ridolfi, L., Porporato, A., y Rodriguez-Iturbe, I. (2000), Preferential states of seasonal soil moisture: The impact of climate fluctuations, *Water Resources Research*, 36(8), 2209–2219.
- [28] Dorigo, W. A., Scipal, K., Parinussa, R. M., Liu, Y. Y., Wagner, W., De Jeu, R. A., y Naeimi, V. (2010), Error characterisation of global active and passive microwave soil moisture datasets, *Hydrology and Earth System Sciences*, 14(12), 2605.
- [29] FAO, (1998), Digital soil map of the world and derived soil properties, *Land and Water Digital Media Series*, Food and Agriculture Organization.
- [30] Farahmand, A., y AghaKouchak, A. (2015), A generalized framework for deriving nonparametric standardized drought indicators, *Advances in Water Resources*, 76, 140–145.
- [31] Fondo Monetario Internacional (FMI). (1990), Primary Commodities: Market Developments and Outlook, pp. 12.
- [32] Franchini, M., y Pacciani, M. (1991), Comparative analysis of several conceptual rainfall-runoff models, *Journal of Hydrology*, 122(1-4), 161–219.
- [33] Galmarini M. (2003), Sequía en la pampa húmeda, *Clarín Rural*, pp. 8.
- [34] Gao, H., Tang, Q., Shi, X., Zhu, C., Bohn, T. J., Su, F., ... y Wood, E. F. (2010), Water budget record from Variable Infiltration Capacity (VIC) model, *Algorithm Theoretical Basis Document for Terrestrial Water Cycle Data Records*.
- [35] García, N. O., y Vargas, W. M. (1996), The spatial variability of runoff and precipitation in the Rio de la Plata basin, *Hydrological sciences journal*, 41(3), 279–299.
- [36] García, N. O., y Vargas, W. M. (1998), The temporal climatic variability in the ‘Río de la Plata’ basin displayed by the river discharges, *Climatic Change*, 38(3), 359–379.
- [37] Garreaud, R. D., Vuille, M., Compagnucci, R., y Marengo, J. (2009), Present-day south american climate., *Palaeogeography, Palaeoclimatology, Palaeoecology*, 281(3), 180–195.
- [38] Grayson, R. B., Western, A. W., Chiew, F. H., y Blöschl, G. (1997), Preferred states in spatial soil moisture patterns: Local and nonlocal controls, *Water Resources Research*, 33(12), 2897–2908.

- [39] Grimm, A. M., Barros, V. R., y Doyle, M. E. (2000), Climate variability in southern South America associated with El Niño and La Niña events, *Journal of climate*, 13(1), 35–58.
- [40] Grimson, R., Montroull, N., Saurral, R., Vasquez, P., y Camilloni, I. (2013), Hydrological modelling of the Iberá Wetlands in southeastern South America, *Journal of hydrology*, 503, 47–54.
- [41] Gringorten, I. I. (1963), A plotting rule for extreme probability paper, *Journal of Geophysical Research*, 68(3), 813–814.
- [42] Guttman, N. B. (1999), Accepting the standardized precipitation index: A calculation algorithm1, *J. Am. Water Resour. Assoc.*, 35(2), 311–322.
- [43] Hansen, M. C., DeFries, R. S., Townshend, J. R., y Sohlberg, R. (2000), Global land cover classification at 1 km spatial resolution using a classification tree approach, *International journal of remote sensing*, 21(6-7), 1331–1364.
- [44] Hao, Z., y AghaKouchak, A. (2014), A nonparametric multivariate multi-index drought monitoring framework, *Journal of Hydrometeorology*, 15(1), 89–101.
- [45] Hao, Z., AghaKouchak, A., Nakhjiri, N., y Farahmand, A. (2014), Global integrated drought monitoring and prediction system, *Scientific data*, 1.
- [46] Hartmann, T., Di Bella, C., y Oricchio, P., (2003), Assessment of the possible drought impact on farm production in the SE of the province of Buenos Aires, Argentina, *ISPRS J. Photogramm. Remote Sens*, 54(4), 281–288.
- [47] Hayes, M. J., Svoboda, M. D., Wilhite, D. A., y Vanyarkho, O. V. (1999), Monitoring the 1996 drought using the standardized precipitation index, *Bulletin of the American Meteorological Society*, 80(3), 429.
- [48] Hayes, M. J. (2006), Drought indices. John Wiley & Sons, Inc.
- [49] Hayes, M., Svoboda, M., Wall, N., y Widhalm, M. (2011). The Lincoln declaration on drought indices: universal meteorological drought index recommended, *Bulletin of the American Meteorological Society*, 92(4), 485.
- [50] Heim Jr, R. R. (2002), A review of twentieth-century drought indices used in the United States, *Bulletin of the American Meteorological Society*, 83(8), 1149.
- [51] Jaime, P., Menéndez, A. N., Uriburu Quirno, M., y Torchio, J. (2002), Análisis del régimen hidrológico de los ríos Paraná y Uruguay, *Informe INA LHA 216*, 150 pp.
- [52] Junquas, C., Vera, C., Li, L., y Le Treut, H. (2012). Summer precipitation variability over Southeastern South America in a global warming scenario, *Climate dynamics*, 38(9-10), 1867–1883.

- [53] Juran, J. M., y Gryna, F. M. (1970), Quality planning and analysis, *New York: McGraw-Hill*.
- [54] Kalnay, E., Kanamitsu, M., Kistler, R., Collins, W., Deaven, D., Gandin, L., ..., y Zhu, Y. (1996), The NCEP/NCAR 40-year reanalysis project, *Bull. Amer. Meteor. Soc.*, *77*(3), 437–471.
- [55] Kanamitsu, M., Ebisuzaki, W., Woollen, J., Yang, S. K., Hnilo, J. J., Fiorino, M., y Potter, G. L. (2002), Ncep–doe amip-ii reanalysis (r-2), *Bull. Amer. Meteor. Soc.*, *83*(11), 1631–1643.
- [56] Keyantash, J., y J. A. Dracup. (2002), The quantification of drought: An evaluation of drought indices, *Bull. Amer. Meteor. Soc.*, *83*, 1167–1180.
- [57] Koster, R. D., Dirmeyer, P. A., Guo, Z., Bonan, G., Chan, E., Cox, P., ... y Yamada, T. (2004), Regions of strong coupling between soil moisture and precipitation, *Science*, *305*(5687), 1138–1140.
- [58] Krepper, C. M., y Sequeira, M. E. (1998), Low frequency variability of rainfall in southeastern South America, *Theoretical and applied climatology*, *61*(1-2), 19–28.
- [59] Krepper, C. M., y Zucarelli, G. V. (2010), Climatology of water excesses and shortages in the La Plata Basin, *Theoretical and Applied Climatology*, *102*, 13–27.
- [60] Krishna, K. R. (2015), Agricultural Prairies: Natural Resources and Crop Productivity, *CRC Press*.
- [61] Labraga, J. C., Scian, B., y Frumento, O. (2002), Anomalies in the atmospheric circulation associated with the rainfall excess or deficit in the Pampa Region in Argentina, *Journal of Geophysical Research: Atmospheres*, *107*(D23).
- [62] Leva, P. E., Garcia, M. S., Toffoli, G., y Valtorta, S. E. (2012). Caracterización agroclimática de las sequías (1970-2009) en dos localidades del norte santafesino, *FAVE Sección Ciencias Agrarias*, *11*(2), 63–68.
- [63] Liang, X., Lettenmaier, D. P., Wood, E. F., y Burges, S. J. (1994), A simple hydrologically based model of land surface water and energy fluxes for general circulation models, *Journal of Geophysical Research: Atmospheres*, *99*(D7), 14415–14428.
- [64] Liang, X., D. P. Lettenmaier, y Wood, E. F. (1996a), A one-dimensional statistical dynamic representation of subgrid spatial variability of precipitation in the two-layer variable infiltration capacity model, *J. Geophys. Res.*, *101*(D16), 21403–21422.
- [65] Liang, X., Wood, E. F., y Lettenmaier, D. P. (1996b), Surface soil moisture parameterization of the VIC-2L model: Evaluation and modification, *Global and Planetary Change*, *13*(1), 195–206.

- [66] Liu, Y. Y., Parinussa, R. M., Dorigo, W. A., De Jeu, R. A., Wagner, W., Van Dijk, A. I. J. M., ... y Evans, J. P. (2011), Developing an improved soil moisture dataset by blending passive and active microwave satellite-based retrievals, *Hydrology and Earth System Sciences*, *15*(2), 425–436.
- [67] Liu, Y. Y., Dorigo, W. A., Parinussa, R. M., de Jeu, R. A., Wagner, W., McCabe, M. F., ... y Van Dijk, A. I. J. M. (2012), Trend-preserving blending of passive and active microwave soil moisture retrievals, *Remote Sensing of Environment*, *123*, 280–297.
- [68] Livneh, B., Bohn, T. J., Pierce, D. W., Munoz-Arriola, F., Nijssen, B., Vose, R., ..., y Brekke, L. (2015), A spatially comprehensive, hydrometeorological data set for Mexico, the US, and Southern Canada 1950–2013, *Scientific data*, *2*.
- [69] Llano, M. P., y Penalba, O. C. (2011), A climatic analysis of dry sequences in Argentina, *International journal of climatology*, *31*(4), 504–513.
- [70] Lloyd-Hughes, B., y Saunders, M. A. (2002), A drought climatology for Europe, *International journal of climatology*, *22*(13), 1571–1592.
- [71] Lovino, M., García, N. O., y Baethgen, W. (2014), Spatiotemporal analysis of extreme precipitation events in the Northeast region of Argentina (NEA), *Journal of Hydrology: Regional Studies*, *2*, 140–158.
- [72] Luo, L., y Wood, E. F., (2007). Monitoring and predicting the 2007 US drought, *Geophysical Research Letters*, *34*(22).
- [73] Mahrt, L., y Pan, H. (1984), A two-layer model of soil hydrology, *Boundary-Layer Meteorology*, *29*(1), 1–20.
- [74] Malaka, I., y Nuñez, S. (1980), Aspectos sinópticos de la sequía que afectó a la República Argentina en 1962, *Geoacta*, *10*(2), 1–22.
- [75] Maurer, E. P., O'Donnell, G. M., Lettenmaier, D. P., y Roads, J. O. (2001), Evaluation of the land surface water budget in NCEP/NCAR and NCEP/DOE reanalyses using an off-line hydrologic model, *Journal of Geophysical Research: Atmospheres*, *106*(D16), 17841–17862.
- [76] Maurer, E. P., Wood, A. W., Adam, J. C., Lettenmaier, D. P., y Nijssen, B. (2002), A long-term hydrologically based dataset of land surface fluxes and states for the conterminous United States, *Journal of climate*, *15*(22), 3237–3251.
- [77] McKee, T. B., N. J. Doesken, y J. Kleist. (1993), The relationship of drought frequency and duration to time scales. Preprints, Eighth Conf. on Applied Climatology, Anaheim, CA, *Amer. Meteor. Soc.*, 179–184.
- [78] McKee, T. B., N. J. Doesken, y J. Kleist. (1995), Drought monitoring with multiple time scales. Preprints, Ninth Conf. on Applied Climatology, Dallas, TX, *Amer. Meteor. Soc.*, 233–236.

- [79] Mechoso, R. C., Dias, P. S., Baethgen, W., Barros, V., Berbery, E. H., Clarke, R., ... y Lettenmaier, D. (2001), Climatology and hydrology of the La Plata Basin, *VAMOS Scientific Study Group on the Plata Basin*, 56p.
- [80] Meng, J., R. Yang, H. Wei, M. Ek, G. Gayno, P. Xie, y K. Mitchell, (2012), The Land Surface Analysis in the NCEP Climate Forecast System Reanalysis, *J. Hydrometeor.*, *13*, 1621–1630.
- [81] Minetti, J. L. y Vargas, W. M. (1998), Trends and jumps in the annual precipitation in South America, south of 15°S, *Atmosfera*, *11*, 205–221.
- [82] Minetti, J. L., Vargas, W. M., Vega, B., y Costa, M. C. (2007), Las sequías en la Pampa Húmeda: Impacto en la productividad del maíz, *Revista Brasileira de Meteorología*, *22*(2), 218–232.
- [83] Mishra, A. K., Singh, V. P., y Desai, V. R. (2009), Drought characterization: A probabilistic approach, *Stochastic Environmental Research & Risk Assessment*, *23*(1), 41–55.
- [84] Mishra, A. K., y Singh, V. P. (2010), A review of drought concepts, *Journal of Hydrology*, *391*(1), 202–216.
- [85] Mishra, A. K., y Singh, V. P. (2011). Drought modeling—A review, *Journal of Hydrology*, *403*(1), 157–175.
- [86] Mo, K. C. (2008), Model-based drought indices over the United States, *Journal of Hydro-meteorology*, *9*(6), 1212–1230.
- [87] Mo, K. C., y Schemm, J. E. (2008), Relationships between ENSO and drought over the southeastern United States, *Geophysical Research Letters*, *35*(15).
- [88] Mo, K. C., y Berbery, E. H. (2011), Drought and persistent wet spells over South America based on observations and the US CLIVAR drought experiments, *Journal of Climate*, *24*(6), 1801–1820.
- [89] Moriasi, D. N., Arnold, J. G., Van Liew, M. W., Bingner, R. L., Harmel, R. D., y Veith, T. L. (2007), Model evaluation guidelines for systematic quantification of accuracy in watershed simulations, *Transactions of the ASABE*, *50*(3), 885–900.
- [90] Morid, S., Smakhtin, V., y Moghaddasi, M. (2006). Comparison of seven meteorological indices for drought monitoring in Iran, *International journal of climatology*, *26*(7), 971–985.
- [91] Müller, O. V., Berbery, E. H., Alcaraz-Segura, D., y Ek, M. B. (2014), Regional model simulations of the 2008 drought in southern South America using a consistent set of land surface properties, *Journal of Climate*, *27*(17), 6754–6778.

- [92] National Center for Atmospheric Research Staff (Eds). (2013), Last modified 23 Jul 2013. The Climate Data Guide: Common Spectral Model Grid Resolutions, <https://climatedataguide.ucar.edu/climate-model-evaluation/common-spectral-model-grid-resolutions>.
- [93] Naumann, G., Vargas, W. M., y Minetti, J. L. (2008), Estudio de secuencias secas en la Cuenca del Plata: Implicancias con las sequías, *Meteorologica*, 33(1-2), 65–81.
- [94] Nijssen, B., Schnur, R., y Lettenmaier, D. P. (2001), Global retrospective estimation of soil moisture using the variable infiltration capacity land surface model, 1980-93, *Journal of Climate*, 14(8), 1790–1808.
- [95] Paegle, J. N., y Mo, K. C. (2002), Linkages between summer rainfall variability over South America and sea surface temperature anomalies, *Journal of Climate*, 15(12), 1389–1407.
- [96] Palmer, W. C. (1965), Meteorological drought (Vol. 30). Washington, DC, USA *US Department of Commerce, Weather Bureau*.
- [97] Penalba, O. C., y Vargas, W. M. (2004), Interdecadal and interannual variations of annual and extreme precipitation over central-northeastern Argentina, *International Journal of Climatology*, 24(12), 1565–1580.
- [98] Penalba, O. C., Bettolli, M. L., y Vargas, W. M. (2007), The impact of climate variability on soybean yields in Argentina. Multivariate regression, *Meteorological applications*, 14(1), 3–14.
- [99] Penalba, O. y Llano, M. P. (2008), Contribución al estudio de las secuencias secas en la zona agropecuaria de Argentina, *Meteorologica*, 33, 51–64.
- [100] Penalba, O. C., y Vargas, W. M. (2008), Variability of low monthly rainfall in La Plata Basin, *Meteorological Applications*, 15(3), 313–323.
- [101] Penalba, O. C., y Rivera, J. A. (2013). Future changes in drought characteristics over Southern South America projected by a CMIP5 ensemble, *American Journal Climate Change*, 2(3), 173–182 doi:10.4236/ajcc.2013.23017.
- [102] Penalba, O. C., y Rivera, J. A. (2015). Comparación de seis índices para el monitoreo de sequías meteorológicas en el sur de Sudamérica, *Meteorológica*, 40(2), 33–57.
- [103] Penalba, O. C., y Rivera, J. A. (2016a). Regional aspects of future precipitation and meteorological drought characteristics over Southern South America projected by a CMIP5 multi-model ensemble, *International Journal of Climatology*, 36(2), 974–986.
- [104] Penalba, O. C., y Rivera, J. A. (2016b). Precipitation response to El Niño/La Niña events in Southern South America—emphasis in regional drought occurrences, *Advances in Geosciences*, 42, 1–14.

- [105] Quiring, A. M., y Papakryiakou, T.N., (2003), An evaluation of agricultural drought indices for the Canadian prairies, *Agric For Meteorol*, 118, 49–62.
- [106] Quiring, S. M. (2009), Developing objective operational definitions for monitoring drought, *Journal of Applied Meteorology and Climatology*, 48(6), 1217–1229.
- [107] Rao, P. (1993), Inter-Country Comparisons of Agricultural Output and Productivity.
- [108] Redmond, K. T. (2002), The depiction of drought, *Bull. Amer. Meteor. Soc.*, 83, 1143–1147.
- [109] Reschenhofer, E. (2001), The bimodality principle, *J. Stat. Educ.*, 9(1), 1–16.
- [110] Revista IDIA XXI. (2004), Cereales, 6, 72–91.
- [111] Rivera, J. A., y Penalba, O. C. (2014). Trends and spatial patterns of drought affected area in Southern South America., *Climate*, 2(4), 264–278.
- [112] Rodell, M., Houser, P. R., Jambor, U. E. A., Gottschalck, J., Mitchell, K., Meng, C. J., ... y Toll, D. (2004), The global land data assimilation system, *Bulletin of the American Meteorological Society*, 85(3), 381–394.
- [113] Ropelewski, C. F., y Halpert, M. S. (1987), Global and regional scale precipitation patterns associated with the El Niño/Southern Oscillation, *Monthly weather review*, 115(8), 1606–1626.
- [114] Saha, S., Moorthi, S., Pan, H. L., Wu, X., Wang, J., Nadiga, S., ..., y Liu, H. (2010), The NCEP climate forecast system reanalysis, *Bulletin of the American Meteorological Society*, 91(8), 1015.
- [115] Saha, S., Moorthi, S., Wu, X., Wang, J., Nadiga, S., Tripp, P., ..., y Ek, M. (2014). The NCEP climate forecast system version 2, *Journal of Climate*, 27(6), 2185–2208.
- [116] Saurral, R. I., Barros, V. R., y Lettenmaier, D. P. (2008), Land use impact on the Uruguay River discharge, *Geophysical Research Letters*, 35(12).
- [117] Seager, R., Naik, N., Baethgen, W., Robertson, A., Kushnir, Y., Nakamura, J., y Jurburg, S. (2010), Tropical oceanic causes of interannual to multidecadal precipitation variability in southeast south America over the past century, *Journal of Climate*, 23(20), 5517–5539.
- [118] Sheffield, J., Goteti, G., Wen, F., y Wood, E. F. (2004), A simulated soil moisture based drought analysis for the United States, *Journal of Geophysical Research: Atmospheres*, 109(D24).
- [119] Sheffield, J., Goteti, G., y Wood, E. F. (2006), Development of a 50-year high-resolution global dataset of meteorological forcings for land surface modeling, *Journal of Climate*, 19(13), 3088–3111.

- [120] Sheffield, J., y Wood, E. F. (2007), Characteristics of global and regional drought, 1950–2000: Analysis of soil moisture data from off-line simulation of the terrestrial hydrologic cycle, *Journal of Geophysical Research: Atmospheres*, 11(D17).
- [121] Sheffield, J., y Wood, E. F. (2008), Global trends and variability in soil moisture and drought characteristics, 1950–2000, from observation-driven simulations of the terrestrial hydrologic cycle, *Journal of Climate*, 21(3), 432–458.
- [122] Sheffield, J., y Wood, E. F. (2012), Drought: past problems and future scenarios, *Routledge*.
- [123] Shukla, S., Sheffield, J., Wood, E. F., y Lettenmaier, D. P. (2013), On the sources of global land surface hydrologic predictability. Hydrol, *Earth Syst. Sci*, 17(7), 2781–2796.
- [124] Shuttleworth, W. J. (1993), Evaporation in: Maidment, D.R., *Handbook of Hydrology*, McGraw-Hill New York.
- [125] Siebert, S., Henrich, V., Frenken, K., y Burke, J. (2013), Update of the digital global map of irrigation areas to version 5. Rheinische Friedrich-Wilhelms-Universität, Bonn, Germany, *Food and Agriculture Organization of the United Nations*, Rome, Italy.
- [126] Silva, V. B., Kousky, V. E., y Higgins, R. W. (2011). Daily precipitation statistics for South America: An intercomparison between NCEP reanalyses and observations, *Journal of Hydrometeorology*, 12(1), 101–117.
- [127] Silva, V., y Kousky, V. E. (2012). 05 The South American Monsoon System: Climatology and Variability, *InTech*.
- [128] Silvestri, G. E. (2005). Comparison between winter precipitation in southeastern South America during each ENSO phase, *Geophysical research letters*, 32(5).
- [129] Skansi, M.M., S. E. Núñez, G. P. Podestá, H. Veiga y N. Garay (2009), La sequía del año 2008 en la región húmeda argentina descripta a través del Índice de Precipitación Estandarizado, *CONGREGMET 2009*, Buenos Aires, 5-9 October 2009.
- [130] Skansi, M., Veiga, H., Garay, N. G., y Podestá, G. (2012), Periodos secos en la región noreste de Argentina descriptos con el índice de precipitación estandarizado, *CONGREGMET 2012*, Mendoza, 28 Mayo-1 Junio 2012.
- [131] Su, F., y Lettenmaier, D. P. (2009), Estimation of the surface water budget of the La Plata Basin, *Journal of Hydrometeorology*, 10(4), 981–998.
- [132] Svoboda, M. D., M. J. Hayes, y Wilhite, D. A. (2002), The role of integrated drought monitoring in drought mitigation planning, *Annals of Arid Zone*, 40(1), 1-11.
- [133] Thompson, L.M., 1963, Weather and technology in the production of corn and soybeans, *CAED Rep. 17*, Iowa State University. Center of Agric. And Economic Develop.

- [134] Tirso Fiorotto D. (2004), La crisis energética: dificultades por el bajo caudal del río Uruguay, *Clarín Rural*, pp. 10.
- [135] Todini, E. (1996), The ARNO rainfall—runoff model, *Journal of Hydrology*, 175(1), 339–382.
- [136] Tucci, C. E. (2001), Some scientific challenges in the development of South America's water resources, *Hydrological sciences journal*, 46(6), 937–946.
- [137] UNESCO-WWAP (United Nations Educational, Scientific and Cultural Organization-World Water Assessment Program) (2007), The La Plata basin case study, *Final Report*, pp. 516.
- [138] Vargas, W. M. y M. N. Nuñez (1991), El clima y aspectos económicos, *Boletín Informativo de Techint*, 263, 53–68.
- [139] Vargas, W. M., Naumann, G., y Minetti, J. L. (2010), Dry spells in the River Plata Basin: an approximation of the diagnosis of droughts using daily data, *Theoretical and applied climatology*, 104(1-2), 159–173.
- [140] Vicente-Serrano, S. M., Beguería, S., y López-Moreno, J. I. (2010), A multiscalar drought index sensitive to global warming: the standardized precipitation evapotranspiration index, *Journal of Climate*, 23(7), 1696–1718.
- [141] Viglizzo, E. F., y Frank, F. C. (2006). Ecological interactions, feedbacks, thresholds and collapses in the Argentine Pampas in response to climate and farming during the last century, *Quaternary International*, 158(1), 122–126.
- [142] Wagner, W., Blöschl, G., Pampaloni, P., Calvet, J. C., Bizzarri, B., Wigneron, J. P., y Kerr, Y. (2007), Operational readiness of microwave remote sensing of soil moisture for hydrologic applications, *Hydrology Research*, 38(1), 1–20.
- [143] Webber, J. (2012), Argentina's drought: counting the costs, *Financial Times*, Jan 23, 2012.
- [144] Western, A. W., Grayson, R. B., y Blöschl, G. (2002), Scaling of soil moisture: A hydrologic perspective, *Annual Review of Earth and Planetary Sciences*, 30(1), 149–180.
- [145] Wilhite, D. A. (2000), Drought as a natural hazard: concepts and definitions., *D.A. Wilhite (Ed.), Drought: A Global Assessment, vol. 1, Routledge, New York*, pp. 1-18.
- [146] Wilhite, D. A. (2006), Drought monitoring, mitigation, and preparedness in the US: An end to end approach, *Task Force on Socio-Economic Application of Public Water Services*, WMO, Geneva 15-18 May.
- [147] Wilhite, D. A. (Ed.) (2016), Droughts: A Global Assesment, *Routledge*,

- [148] Wilks D. S. (2006), *Statistical Methods in the Atmospheric Sciences*, Elsevier Inc., 627 pp. UK.
- [149] Wood, E. F., Lettenmaier, D. P., y Zartarian, V. G. (1992). A land-surface hydrology parameterization with subgrid variability for general circulation models, *Journal of Geophysical Research: Atmospheres*, 97(D3), 2717–2728.
- [150] Wood, E. F., Lettenmaier, D., Liang, X., Nijssen, B., y Wetzel, S. W. (1997), Hydrological modeling of continental-scale basins, *Annual Review of Earth and Planetary Sciences*, 25(1), 279–300.
- [151] Xie, Z., Liu, Q., y Su, F. (2004), An application of the VIC-3L land surface model with the new surface runoff model in simulating streamflow for the Yellow River basin, *GIS and Remote Sensing in Hydrology, Water Resources and Environment*, (289)241.
- [152] Xie, P., Chen, M., Yang, S., Yatagai, A., Hayasaka, T., Fukushima, Y., y Liu, C. (2007a). A gauge-based analysis of daily precipitation over East Asia, *Journal of Hydrometeorology*, 8(3), 607–626.
- [153] Xie, Z., Yuan, F., Duan, Q., Zheng, J., Liang, M., y Chen, F. (2007b), Regional parameter estimation of the VIC land surface model: Methodology and application to river basins in China, *Journal of Hydrometeorology*, 8(3), 447–468.
- [154] Yevjevich, V. (1967), An objective approach to definitions and investigations of continental hydrologic droughts, *Hydrology Paper*, Colorado State University, Fort Collins, Colorado.
- [155] Zhao, R. J. (1992), The Xinanjiang model applied in China, *Journal of Hydrology*, 135(1-4), 371–381.

Doctorado en Ingeniería
mención recursos hídricos

Título de la obra:

Modelación de Variables
Hydroclimáticas de Superficie y
Evolución de su Comportamiento en
Eventos Extremos Secos

Autor: Leandro C. Sgroi

Lugar: Santa Fe, Argentina

Palabras Claves:

eventos extremos, índices de monitoreo,
modelación hidrológica,
climatología de eventos extremos,
impactos agrícolas,
sistema de monitoreo y pronóstico de eventos extremos.